

UNIVERSIDADE FEDERAL DA GRANDE DOURADOS
FACULDADE DE ADMINISTRAÇÃO, CIÊNCIAS CONTÁBEIS E ECONOMIA
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONEGÓCIOS

**“IMPACTOS DAS VARIÁVEIS CLIMÁTICAS SOBRE A PRODUTIVIDADE DA
SOJA E DO MILHO NO BRASIL ENTRE 2012 E 2024: EVIDÊNCIAS DA
ADAPTAÇÃO CLIMÁTICA”**

Leucivaldo Carneiro Moraes

DOURADOS-MS

2026

UNIVERSIDADE FEDERAL DA GRANDE DOURADOS
FACULDADE DE ADMINISTRAÇÃO, CIÊNCIAS CONTÁBEIS E ECONOMIA
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONEGÓCIOS

**“IMPACTOS DAS VARIÁVEIS CLIMÁTICAS SOBRE A PRODUTIVIDADE DA
SOJA E DO MILHO NO BRASIL ENTRE 2012 E 2024: EVIDÊNCIAS DA
ADAPTAÇÃO CLIMÁTICA”**

Tese apresentada ao Programa de Pós-Graduação em Agronegócios da Universidade Federal da Grande Dourados – Faculdade de Administração, Ciências Contábeis e Economia, como requisito para a obtenção do título de Doutor em Agronegócios.

Discente: Leucivaldo Carneiro Moraes

Orientador: Prof. Dr. Jonathan Gonçalves da Silva

Coorientadores: Prof. Dr. Leandro Vinícios Carvalho

Dra. Roselaine Bonfim de Almeida

DOURADOS-MS

2026

FICHA CATOLOGRÁFICA

Dados Internacionais de Catalogação na Publicação (CIP).

M828" Morais, Leucivaldo Carneiro
 "IMPACTOS DAS VARIÁVEIS CLIMÁTICAS SOBRE A PRODUTIVIDADE DA SOJA E
 DO MILHO NO BRASIL ENTRE 2012 E 2024: EVIDÊNCIAS DA ADAPTAÇÃO
 CLIMÁTICA" [recurso eletrônico] / Leucivaldo Carneiro Morais. -- 2026.
 Arquivo em formato pdf.

Orientador: Dr. Jonathan Gonçalves da Silva.
Coorientadores: Dr. Leandro Vinícios Carvalho, Dra. Roselaine Bonfim de Almeida.
Tese (Doutorado em Agronegócios)-Universidade Federal da Grande Dourados, 2026.
Disponível no Repositório Institucional da UFGD em:
<https://portal.ufgd.edu.br/setor/biblioteca/repositorio>

1. Mudanças Climáticas. 2. Produtividade Agrícola. 3. Adaptação Climática. 4. Soja e
Milho. 5. Dados em Pannel. I. Silva, Dr. Jonathan Gonçalves Da. II. Carvalho, Dr. Leandro
Vinícios. III. Almeida, Dra. Roselaine Bonfim De. IV. Título.

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

©Direitos reservados. Permitido a reprodução parcial desde que citada a fonte.

ATA DE APROVAÇÃO



Ministério da Educação
Fundação Universidade Federal da Grande Dourados
Pró-Reitoria de Pós-Graduação
Coordenadoria de Pós-Graduação



ATA DA DEFESA DE TESE DE DOUTORADO APRESENTADA POR LEUCIVALDO CARNEIRO MORAIS, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONEGÓCIOS, ÁREA DE CONCENTRAÇÃO "AGRONEGÓCIOS E SUSTENTABILIDADE".

Aos vinte e quatro dias do mês de agosto do ano de dois mil e vinte e seis, às oito horas, em sessão pública, realizou-se na Universidade Federal da Grande Dourados, a Defesa de Tese de Doutorado intitulada **"IMPACTOS DAS VARIÁVEIS CLIMÁTICAS SOBRE A PRODUTIVIDADE DA SOJA E DO MILHO NO BRASIL ENTRE 2012 E 2024: EVIDÊNCIAS DA ADAPTAÇÃO CLIMÁTICA"**, apresentada pela pessoa doutoranda Leucivaldo Carneiro Moraes, do Programa de Pós-graduação em Agronegócios, à Banca Examinadora constituída pelos membros: Prof. Dr. Jonathan Gonçalves da Silva/UFGD (presidente/orientador), Prof. Dr. Antonio Carlos Vaz Lopes/UFGD (membro titular interno), Prof. Dr. Rafael Martins Noriller/UFGD (membro titular interno), Prof.ª Dr.ª Nathalia Sbarai/UFVJM (membro titular externo), Prof. Dr. Victor Azambuja Gama/UEMS (membro titular externo). Iniciados os trabalhos, a presidência deu a conhecer à pessoa candidata e aos integrantes da banca as normas a serem observadas na apresentação da Tese. Após a pessoa candidata ter apresentado a sua Tese, os membros da Banca Examinadora fizeram suas arguições. Terminada a Defesa, a Banca Examinadora, em sessão secreta, passou aos trabalhos de julgamento, tendo a pessoa candidata obtido a aprovação. Nada mais havendo a tratar, lavrou-se a presente ata, que vai assinada pelos membros da Comissão Examinadora.

Dourados/MS, 24 de agosto de 2026.

Documento assinado digitalmente
 JONATHAN GONCALVES DA SILVA
Data: 24/08/2026 12:59:23-0300
Verifique em <https://validar.jf.gov.br>

Prof. Dr. Jonathan Gonçalves da Silva
Presidente/Orientador

Documento assinado digitalmente
 ANTONIO CARLOS VAZ LOPES
Data: 01/09/2026 23:25:09-0300
Verifique em <https://validar.jf.gov.br>

Prof. Dr. Antonio Carlos Vaz Lopes
Membro Titular Interno

Documento assinado digitalmente
 RAFAEL MARTINS NORILLER
Data: 28/08/2026 17:32:28-0300
Verifique em <https://validar.jf.gov.br>

Prof. Dr. Rafael Martins Noriller
Membro Titular Interno

Documento assinado digitalmente
 NATHALIA SBARAI
Data: 25/08/2026 13:13:54-0300
Verifique em <https://validar.jf.gov.br>

Prof.ª. Dr.ª Nathalia Sbarai
Membro Titular Externo

Documento assinado digitalmente
 VICTOR AZAMBUJA GAMA
Data: 28/08/2026 17:14:38-0300
Verifique em <https://validar.jf.gov.br>

Prof. Dr. Victor Azambuja Gama
Membro Titular Externo

(PARA USO EXCLUSIVO DA PROPG)

ATA HOMOLOGADA PELA PRÓ-REITORIA DE PÓS-GRADUAÇÃO DA UFGD
PROPG/UFGD

DEDICATÓRIA

A Deus, pela vida, pela força e pela oportunidade de chegar até aqui.

À minha família, pelo amor, apoio e compreensão ao longo desta trajetória.

À minha esposa **Letícia** e aos meus filhos, **Lavínia, Layza e Mauro Henrique**, que deram sentido aos esforços e às renúncias necessários para a realização deste sonho.

À minha mãe e a todos aqueles que contribuíram para minha formação humana e profissional.

Minha tia Zilda Pires, pelo incentivos moral e financeiros durante minha vida acadêmica, muito obrigado.

Dedico-lhes esta conquista, resultado de uma caminhada construída com perseverança, aprendizado e esperança.

AGRADECIMENTOS

A Deus, pela vida, pela força, pela sabedoria e por me permitir chegar até este momento. Nos períodos de dificuldades e incertezas, a fé foi fundamental para que eu permanecesse firme na realização deste objetivo.

À minha família, pelo amor, apoio, compreensão e incentivo ao longo de toda esta trajetória. De maneira especial, à minha esposa, Letícia, pela parceria, paciência e compreensão diante das inúmeras horas dedicadas aos estudos e à pesquisa. Aos meus filhos, Lavínia, Layza e Mauro Henrique, pelo carinho e por representarem uma das principais razões para que eu continue buscando novos conhecimentos e conquistas.

À minha mãe, por todos os ensinamentos, pelo exemplo de vida e pelo apoio ao longo de minha formação pessoal e profissional. Estendo minha gratidão aos demais familiares que, de diferentes maneiras, contribuíram e torceram pela concretização desta etapa.

Ao meu orientador, Professor Dr. Jonathan Gonçalves da Silva, e aos meus coorientadores, Professor Dr. Leandro Vinícios Carvalho e Professora Dra. Roselaine Bonfim de Almeida, pela orientação, disponibilidade, confiança e pelas contribuições acadêmicas fundamentais para o desenvolvimento e o aprimoramento desta tese. Aos professores do Programa de Pós-Graduação em Agronegócios da Universidade Federal da Grande Dourados (UFGD), pelos conhecimentos compartilhados, pelas discussões acadêmicas e pelas contribuições proporcionadas durante o curso. Aos professores que compuseram as bancas de avaliação deste trabalho, pela disponibilidade, pela leitura criteriosa e pelas valiosas observações, críticas e sugestões, que contribuíram para o aperfeiçoamento da pesquisa.

Aos colegas do Programa de Pós-Graduação em Agronegócios, pelo convívio, pelas experiências compartilhadas e pelo apoio durante esta caminhada acadêmica. Em especial, agradeço a Maurício Hiroyuki Kubo, Juliano dos Santos Cardoso, Vilson Pedro Nery, Rafael Fausto, Victor e João, pela amizade, pelo companheirismo e pelos momentos compartilhados ao longo desta trajetória. Muito obrigado.

Por fim, agradeço a todas as pessoas que, direta ou indiretamente, participaram desta caminhada. Cada palavra de incentivo, contribuição acadêmica e gesto de apoio teve importância para que este trabalho fosse concluído.

SUMÁRIO

1. INTRODUÇÃO	14
1.1 Objetivo Geral.....	16
1.2 Objetivos Específicos.....	16
1.3 Justificativa e Hipóteses de Pesquisa	16
2. REVISÃO DA LITERATURA	20
2.1 Mudanças climáticas e produtividade agrícola	20
2.2 Modelos de Paineis e Economia do Clima	24
2.3 Não linearidade climática	27
2.4 Adaptação climática.....	31
3. DADOS E METODOLOGIA	39
3.1 Estratégia empírica	39
3.2 Especificação dos modelos econométricos	40
3.2.1 Modelo baseline.....	41
3.2.2 Modelo de não linearidade climática.....	42
3.2.3 Modelo de adaptação climática	43
3.6 Base de dados e variáveis	44
3.7 Definição das variáveis	46
3.8 Seleção do estimador.....	48
3.9 Testes de diagnóstico	50
3.10 Procedimentos de robustez.....	51
3.12 Modelo <i>Pooled</i> (POLS).....	53
3.13 Modelo de Efeitos Fixos	54
3.14 Modelo de Efeitos Aleatórios	56
3.15 Testes de Especificação	58
3.16 Teste F de Chow	58
3.17 Teste do Multiplicador de Lagrange	59
3.18 Teste de Hausman.....	60
3.19 Testes de Robustez.....	62
4. RESULTADOS E DISCUSSÃO	64
4.1 Análises Exploratória dos Dados	64
4.2 Resultados dos modelos econométricos	92
5. CONSIDERAÇÕES FINAIS	109
REFERÊNCIAS	111

"IMPACTOS DAS VARIÁVEIS CLIMÁTICAS SOBRE A PRODUTIVIDADE DA SOJA E DO MILHO NO BRASIL ENTRE 2012 E 2024: EVIDÊNCIAS DA ADAPTAÇÃO CLIMÁTICA"

RESUMO

As mudanças climáticas representam um dos principais desafios para a agricultura brasileira, especialmente para culturas estratégicas como soja e milho, cuja produtividade depende diretamente das condições de temperatura e precipitação. Esta tese teve como objetivo analisar os impactos das variáveis climáticas sobre a produtividade agrícola da soja e do milho no Brasil, considerando possíveis efeitos não lineares e evidências de adaptação climática no período de 2012 a 2024. Foram utilizados dados do Sistema IBGE de Recuperação Automática (SIDRA/IBGE), do Instituto Nacional de Meteorologia (INMET) e do Programa de Garantia da Atividade Agropecuária (Proagro/MAPA), organizados em um painel de dados com 701 observações. A estratégia empírica baseou-se na estimação de modelos de dados em painel com efeitos fixos, compreendendo um modelo baseline, um modelo de não linearidade climática e um modelo de adaptação climática, selecionados a partir de testes de especificação e diagnosticados quanto à robustez dos resíduos. Os resultados indicaram que a temperatura média exerce efeito negativo sobre a produtividade agrícola, enquanto a precipitação apresenta efeito positivo, sendo o milho a cultura mais sensível às variações climáticas. No modelo baseline, verificou-se que um aumento de 1°C na temperatura reduz a produtividade do milho em aproximadamente 6,09%, ao passo que o incremento de 1 mm de precipitação aumenta a produtividade em cerca de 0,31%. Os modelos de não linearidade mostraram evidências de retornos decrescentes da precipitação para o milho, sem evidências robustas de não linearidade da temperatura, enquanto, para a soja, não foram identificados efeitos não lineares estatisticamente significativos. O modelo de adaptação climática evidenciou redução parcial da vulnerabilidade do milho aos efeitos adversos da temperatura ao longo do período analisado, sugerindo que avanços tecnológicos e melhorias no manejo agrícola contribuíram para mitigar parte dos impactos climáticos. Para a soja, entretanto, não foram encontradas evidências estatisticamente significativas de adaptação climática. Conclui-se que as mudanças climáticas afetam significativamente a produtividade agrícola brasileira, especialmente a cultura do milho, reforçando a necessidade de políticas públicas voltadas à adaptação climática, ao desenvolvimento tecnológico e ao fortalecimento da resiliência dos sistemas produtivos frente ao aumento da frequência de eventos climáticos extremos.

Palavras-chave: Mudanças Climáticas; Produtividade Agrícola; Soja; Milho; Dados em Painel; Não Linearidade Climática; Adaptação Climática.

“ IMPACTS OF CLIMATE VARIABLES ON SOYBEAN AND CORN PRODUCTIVITY IN BRAZIL BETWEEN 2012 AND 2024: EVIDENCE OF CLIMATE ADAPTATION.

ABSTRACT

Climate change represents one of the main challenges facing Brazilian agriculture, particularly strategic crops such as soybeans and corn, whose productivity depends directly on temperature and precipitation conditions. This dissertation aimed to analyze the impacts of climate variables on soybean and corn productivity in Brazil, considering potential nonlinear effects and evidence of climate adaptation from 2012 to 2024. Data were obtained from the IBGE System of Automatic Recovery (SIDRA/IBGE), the Brazilian National Institute of Meteorology (INMET), and the Agricultural Activity Guarantee Program (Proagro/MAPA), and organized into a panel dataset comprising 701 observations. The empirical strategy was based on the estimation of fixed-effects panel data models, including a baseline model, a climate nonlinearity model, and a climate adaptation model, selected through specification tests and evaluated through residual diagnostic tests. The results indicated that average temperature has a negative effect on agricultural productivity, whereas precipitation has a positive effect, with corn being the crop most sensitive to climate variations. In the baseline model, a 1°C increase in temperature was associated with an approximately 6.09% reduction in corn productivity, while a 1 mm increase in precipitation was associated with an approximately 0.31% increase in productivity. The nonlinearity models provided evidence of diminishing returns to precipitation for corn, but no robust evidence of temperature nonlinearity. For soybeans, no statistically significant nonlinear effects were identified. The climate adaptation model showed a partial reduction in corn vulnerability to the adverse effects of temperature over the period analyzed, suggesting that technological advances and improvements in agricultural management contributed to mitigating some of the negative climate impacts. For soybeans, however, no statistically significant evidence of climate adaptation was found. The findings indicate that climate change significantly affects Brazilian agricultural productivity, particularly corn production, reinforcing the need for public policies focused on climate adaptation, technological development, and strengthening the resilience of agricultural production systems in response to the increasing frequency of extreme climate events.

Keywords: climate change; agricultural productivity; soybean; corn; panel data; climate nonlinearity; climate adaptation.

LISTAS DE ABREVIATURAS

°C- Unidade de medida de Temperatura em graus Celsius

CONAB - Companhia Nacional de Abastecimento

EA- Efeitos Aleatórios

EF- Efeitos Fixos

EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária

FAO - Organização das Nações Unidas para a Alimentação e a Agricultura

HA- Hectares unidade de medida agrária padronizada usada para calcular áreas de terras rurais

IBGE - Instituto Brasileiro de Geografia e Estatística.

INMET - Instituto Nacional de Meteorologia

IPC- Índice de Preços ao Consumidor

IPCC - Painel Intergovernamental sobre Mudanças Climáticas

KG – Unidade de medida de peso em quilograma

LM- Multiplicador de Lagrange

MAPA - Ministério da Agricultura e Pecuária

MM – Unidade de medida de precipitação em Milímetros

OCDE- Organização para a Cooperação e Desenvolvimento Econômico

ONU - Organização das Nações Unidas

PNUD - Programa das Nações Unidas para o Desenvolvimento

PROAGRO - Programa de Garantia da Atividade Agropecuária

SIDRA - Sistema IBGE de Recuperação Automática (SIDRA/IBGE) – base de dados estatísticos.

UNDP- *United Nations Development Programme*

ZARC- Zoneamento Agrícola de Riscos Climáticos

LISTA DE TABELAS

Tabela 1- Comparação dos riscos com o aumento das temperaturas da terra	36
Tabela 2- Nomenclatura e especificação das variáveis climáticas (2012-2024).	47
Tabela 3- Estatísticas descritivas da temperatura média anual por estado brasileiro (2012–2024).	83
Tabela 4- Estatísticas Descritivas: Produção e eventos climáticos no Brasil (2012-2024).	84
Tabela 5- Análise Descritiva Regional das variáveis climáticas e produtivas no Brasil (2012-2024).	85
Tabela 6- Distribuição dos eventos climáticos extremos por cultura e região (2012-2024).	90
Tabela 7- Resultados dos modelos de efeito fixos: impactos de temperatura e precipitação sobre a produtividade agrícola do milho (2012-2024).	93
Tabela 8 - Modelo de Efeitos Fixos com Não Linearidade Climática do milho (2012-2024).	95
Tabela 9- Resultados do Modelo de Efeitos Fixos com Adaptação Climática do milho (2012-2024).	98
Tabela 10- Resultados do Modelo de Efeitos Fixos (Baseline) da Soja (2012-2024).	101
Tabela 11- Resultados do Modelo de Não Linearidade (Temperatura, Precipitação e Threshold) da soja (2012-2024)	104
Tabela 12- Resultados do Modelo de Adaptação Climática da soja (2012-2024). ...	106

LISTA DE FIGURAS

Figura 1- Fluxograma da estratégia empírica e econométrica da pesquisa.	40
Figura 2 Evolução da produção de soja e milho no Brasil (2012-2024).	64
Figura 3 Produção de milho por Região (2012-2024).....	67
Figura 4 Produção de soja por Região (2012-2024).....	68
Figura 5 Produção de milho por estados levando em consideração o ZARC- Zoneamento Agrícola de Riscos Climáticos (2012-2024).....	68
Figura 6 - Produção de soja por estados levando em consideração o ZARC - Zoneamento Agrícola de Riscos Climáticos (2012-2024).....	69
Figura 7 - Distribuição espacial da precipitação média nos estados brasileiros em 2012, 2018, 2024.	70
Figura 8 - Distribuição espacial da temperatura média anual nos estados brasileiros em diferentes momentos: 2012, 2018, 2024.	73
Figura 9- Números de eventos climáticos extremos por estados no Brasil (2012- 2024).	75
Figura 10 - Eventos de seca por estados (2012-2024).....	76
Figura 11- Eventos de Chuvas em excesso por estados (2012-2024).	77
Figura 12- Matriz de dispersão, histograma e correlação entre rendimento, temperatura e precipitação (2012-2024).	78
Figura 13- Distribuição média de precipitação no Brasil (2012-2024).	79
Figura 14- Distribuição de Precipitação por Região (2012-2024).	80
Figura 15- Distribuição de Precipitação por Estados (2012-2024).	81
Figura 16 - Associação entre a precipitação média anual e o número de eventos de seca registrados nos estados brasileiros entre (2012- 2024).....	86
Figura 17- Relação entre precipitação média anual e eventos de seca nos estados brasileiros (2012-2024).	87
Figura 18 - Evolução dos Eventos de Seca no Brasil (2012-2024).	88

1. INTRODUÇÃO

As mudanças climáticas constituem um dos principais desafios para a agricultura mundial, em razão de seus efeitos sobre a temperatura, a precipitação e a ocorrência de eventos climáticos extremos, fatores que influenciam o desempenho das atividades agropecuárias. O aumento da concentração de gases de efeito estufa tem intensificado o aquecimento global, alterando padrões climáticos e ampliando a frequência e a intensidade de secas, ondas de calor, chuvas intensas e outros eventos extremos. Segundo o Painel Intergovernamental sobre Mudanças Climáticas (IPCC, 2023), a temperatura média global no período de 2011 a 2020 foi aproximadamente 1,1 °C superior aos níveis pré-industriais, evidenciando que as mudanças climáticas já produzem impactos mensuráveis sobre sistemas naturais, econômicos e sociais.

No setor agrícola, esses efeitos assumem importância estratégica devido à elevada dependência da produção em relação às condições climáticas. A temperatura e a disponibilidade hídrica influenciam processos fisiológicos fundamentais das plantas, como germinação, florescimento, enchimento de grãos e maturação, podendo afetar diretamente a produtividade das culturas. Além disso, alterações climáticas persistentes podem modificar calendários agrícolas, ampliar riscos de perdas produtivas e aumentar a volatilidade da oferta de alimentos, com reflexos sobre preços, renda agrícola e segurança alimentar, conforme Wheeler e von Braun (2013).

No contexto brasileiro, essa discussão torna-se ainda mais relevante em razão da posição ocupada pelo país entre os principais produtores e exportadores mundiais de *commodities* agrícolas. A soja e o milho desempenham papel central na economia nacional, contribuindo para o Produto Interno Bruto (PIB) do agronegócio, para a geração de divisas e para o abastecimento dos mercados interno e externo. Entretanto, grande parte dessa produção é desenvolvida em sistemas de sequeiro, tornando-a particularmente sensível às variações de temperatura e precipitação.

Estudos demonstram que as mudanças climáticas já afetam o desempenho agrícola em diferentes regiões do mundo. Lobell, Schlenker (2011) e Costa-Roberts (2011) verificaram que as tendências climáticas observadas desde a década de 1980 reduziram a produção global de importantes culturas agrícolas. De forma complementar, Ortiz-Bobea *et al.* (2021) estimaram que a mudança climática antropogênica reduziu aproximadamente 21% do crescimento da produtividade agrícola global desde 1961, indicando que seus efeitos já podem ser observados nas

séries históricas de produção. Essas evidências reforçam a necessidade de compreender como as condições climáticas influenciam o desempenho agrícola em diferentes contextos regionais.

Apesar do avanço da literatura internacional, ainda permanecem desafios para compreender a magnitude e a forma pela qual temperatura e precipitação afetam a produtividade agrícola no Brasil. A heterogeneidade climática entre as regiões produtoras, a elevada diversidade de sistemas produtivos e as diferenças de manejo agrícola dificultam a generalização de resultados obtidos em outros países. Além disso, parte significativa dos estudos nacionais concentra-se na análise isolada de culturas, regiões ou cenários climáticos específicos, havendo menor número de pesquisas que investigam conjuntamente a produtividade da soja e do milho em escala nacional por meio de métodos econométricos capazes de controlar a heterogeneidade espacial e temporal.

Outro aspecto relevante refere-se ao fato de que os impactos climáticos podem não ocorrer de forma proporcional ao longo de toda a distribuição das variáveis meteorológicas. Pequenas alterações de temperatura ou precipitação podem produzir efeitos distintos daqueles observados em situações de calor extremo ou déficit hídrico severo. Da mesma forma, produtores rurais podem adotar estratégias de adaptação, como alterações no calendário agrícola, utilização de cultivares mais resistentes, melhorias no manejo e incorporação de novas tecnologias, modificando parcialmente a sensibilidade da produção às condições climáticas.

Diante desse contexto, esta pesquisa tem como objetivo analisar os impactos da temperatura e da precipitação sobre a produtividade da soja e do milho no Brasil, considerando possíveis efeitos não lineares e evidências de adaptação climática no período de 2012 a 2024. Para isso, são utilizados dados do Sistema IBGE de Recuperação Automática (SIDRA/IBGE), do Instituto Nacional de Meteorologia (INMET) e do Programa de Garantia da Atividade Agropecuária (Proagro/MAPA), organizados em estrutura de dados em painel.

A estratégia empírica baseia-se na estimação de modelos de efeitos fixos para dados em painel, permitindo controlar características não observadas constantes entre as unidades de análise e explorar a variação temporal das condições climáticas. São estimadas três especificações complementares: um modelo baseline, destinado a mensurar os efeitos médios da temperatura e da precipitação; um modelo de não linearidade, que investiga possíveis respostas diferenciadas da produtividade a

distintos níveis das variáveis climáticas; e um modelo de adaptação climática, que busca identificar se a sensibilidade da produtividade às condições meteorológicas se altera ao longo do tempo.

A principal contribuição desta pesquisa consiste em oferecer evidências empíricas sobre os efeitos das variáveis climáticas na produtividade das duas principais culturas agrícolas brasileiras, incorporando simultaneamente a análise dos efeitos médios, das possíveis não linearidades e das evidências de adaptação em uma estrutura única de dados em painel. Dessa forma, o estudo amplia o conhecimento sobre a relação entre clima e produtividade agrícola no Brasil e fornece subsídios para políticas públicas voltadas à adaptação do setor agropecuário frente às mudanças climáticas.

1.1 Objetivo Geral

Analisar os impactos das variáveis climáticas sobre a produtividade agrícola da soja e do milho no Brasil, considerando explicitamente possíveis efeitos não lineares e mecanismos de adaptação climática entre 2012 e 2024.

1.2 Objetivos Específicos

1. Caracterizar a evolução da produção e da produtividade agrícola da soja e do milho no Brasil, bem como a ocorrência e a distribuição dos principais eventos climáticos extremos no período de 2012 a 2024.
2. Estimar os efeitos da temperatura e da precipitação sobre a produtividade agrícola da soja e do milho por meio de modelos de dados em painel.
3. Avaliar a existência de relações não lineares entre as variáveis climáticas e a produtividade agrícola, investigando possíveis limiares críticos de temperatura e precipitação.
4. Investigar evidências de adaptação climática na produtividade da soja e do milho, por meio da incorporação de um modelo de adaptação em dados em painel.

1.3 Justificativa e Hipóteses de Pesquisa

A agricultura brasileira desempenha papel estratégico para a economia nacional e para a segurança alimentar global, destacando-se pela elevada participação na produção e exportação de *commodities* agrícolas, especialmente soja e milho. Entretanto, apesar dos avanços tecnológicos observados nas últimas décadas, a produtividade dessas culturas permanece sendo dependente das

condições climáticas, uma vez que temperatura e precipitação influenciam processos fisiológicos relacionados ao crescimento, florescimento, enchimento de grãos e rendimento final das lavouras.

A relevância dessa temática torna-se ainda mais evidente diante das crescentes evidências de mudanças climáticas observadas em escala global. De acordo com o IPCC (2023), o aquecimento global tem provocado alterações relevantes nos padrões de temperatura e precipitação, aumentando a frequência e a intensidade de eventos climáticos extremos, como secas, ondas de calor e precipitações intensas. Tais fenômenos representam riscos crescentes para a agricultura, especialmente em países tropicais como o Brasil, onde grande parte da produção agrícola depende das condições naturais de clima e da disponibilidade hídrica.

A literatura internacional demonstra que as variáveis climáticas constituem importantes determinantes da produtividade agrícola. Estudos de Zhao *et al.* (2007), Iizumi *et al.* (2017) e Yu *et al.* (2009) evidenciam que alterações na temperatura e na precipitação afetam o desempenho das culturas agrícolas. No contexto brasileiro, estudos também demonstram a relevância das condições climáticas para o desempenho produtivo das lavouras. Bigolin e Talamini (2024) indicam que cenários de mudanças climáticas podem reduzir a produtividade do sistema de sucessão soja-milho, sobretudo em regiões mais vulneráveis ao aumento da temperatura, enquanto Silva *et al.* (2021) evidenciam a importância das condições de precipitação para o rendimento da soja. Adicionalmente, Batista, Duku e Hein (2023) demonstram que alterações nos padrões de precipitação associadas ao desmatamento podem reduzir os rendimentos do sistema soja-milho no Brasil.

Entretanto, evidências empíricas mostram que a relação entre clima e produtividade agrícola não ocorre de forma estritamente linear. Schlenker e Roberts (2009) demonstraram que a produtividade agrícola responde de maneira assimétrica às variações de temperatura, apresentando perdas crescentes quando determinados limiares térmicos são ultrapassados. De forma semelhante, Gammans, Mérel e Ortiz-Bobea (2017) verificaram que os efeitos negativos do aquecimento se intensificam à medida que a exposição das culturas a temperaturas extremas aumenta. No caso da precipitação, tanto a escassez quanto o excesso de chuvas podem comprometer o desempenho produtivo, sugerindo a existência de relações não lineares entre as condições climáticas e o rendimento agrícola.

Além dos efeitos diretos do clima, a literatura destaca a adaptação climática como um mecanismo potencial de redução da vulnerabilidade da agricultura às mudanças ambientais (Burke; Emerick, 2016; Brumatti; Pires; Santos, 2020). Entre as estratégias de adaptação encontram-se a adoção de cultivares mais resistentes ou adequadas às condições climáticas, a modernização tecnológica, o aprimoramento do manejo agrícola, a irrigação e os ajustes nos calendários de plantio. Entretanto, a capacidade dessas estratégias de compensar os efeitos adversos das mudanças climáticas pode ser limitada e variar conforme as condições produtivas e climáticas (Burke; Emerick, 2016; Brumatti; Pires; Santos, 2020). Nesse sentido, permanece relevante ampliar as evidências empíricas sobre a capacidade de adaptação da agricultura brasileira e sobre a forma como esses mecanismos influenciam a sensibilidade da produtividade agrícola às variações climáticas ao longo do tempo.

Dessa forma, esta pesquisa justifica-se pela relevância econômica da soja e do milho para o agronegócio brasileiro, pela crescente incidência de eventos climáticos extremos e pela necessidade de aprofundar o conhecimento sobre os efeitos da temperatura e da precipitação na produtividade agrícola. Além disso, ao incorporar simultaneamente a análise dos impactos médios do clima, dos efeitos não lineares e dos possíveis mecanismos de adaptação climática, o estudo busca contribuir para o avanço da literatura de economia do clima aplicada à agricultura, fornecendo evidências relevantes para a formulação de políticas públicas e estratégias de adaptação voltadas ao fortalecimento da resiliência do setor agrícola brasileiro.

Com base na literatura e na estratégia empírica adotada nesta pesquisa, parte-se da hipótese de que as variáveis climáticas exercem influência sobre a produtividade agrícola da soja e do milho no Brasil. Especificamente, espera-se que aumentos da temperatura média reduzam o rendimento das culturas, enquanto níveis adequados de precipitação contribuam positivamente para a produtividade agrícola. Adicionalmente, supõe-se que esses efeitos não sejam constantes ao longo da distribuição das variáveis climáticas, apresentando comportamento não linear e intensificando-se quando determinados limiares críticos de temperatura e precipitação são ultrapassados. Assume-se ainda que eventos climáticos extremos, como secas, excesso de precipitação, geadas e ondas de calor, provoquem reduções significativas na produtividade agrícola. Por fim, considera-se a hipótese de que a agricultura brasileira tenha desenvolvido mecanismos de adaptação ao longo do período analisado, de modo que a sensibilidade da produtividade aos efeitos adversos das

condições climáticas tenha diminuído em decorrência da incorporação de tecnologias, inovações produtivas e estratégias de manejo agrícola.

2. REVISÃO DA LITERATURA

Essa organização estabelece uma sequência lógica: primeiro apresenta o fenômeno das mudanças climáticas e seus efeitos sobre a agricultura, depois introduz a perspectiva da economia do clima, em seguida fundamenta o uso dos modelos econométricos de dados em painel e, por fim, revisa as evidências empíricas que sustentam a pesquisa e conduzem ao modelo econométrico adotado.

2.1 Mudanças climáticas e produtividade agrícola

As atividades humanas têm contribuído para o aumento das emissões de gases de efeito estufa e para a intensificação do aquecimento global. Segundo o Painel Intergovernamental sobre Mudanças Climáticas, a temperatura média global entre 2011 e 2020 atingiu aproximadamente 1,1°C acima dos níveis pré-industriais de 1850-1900 (IPCC, 2023). Esse aquecimento já afeta todas as regiões do mundo, intensifica eventos extremos e produz impactos desproporcionais sobre populações vulneráveis, que historicamente contribuíram menos para as emissões globais (IPCC, 2023). O Programa das Nações Unidas para o Desenvolvimento (PNUD) também destaca riscos crescentes relacionados à escassez de recursos naturais, à segurança alimentar, à saúde humana e à integridade dos ecossistemas quando as metas de limitação do aquecimento não são alcançadas (PNUD, 2021).

A relação entre mudanças climáticas e produtividade agrícola tem sido amplamente discutida pela dependência da agricultura em relação à temperatura, à precipitação e à disponibilidade hídrica. Lobell e Field (2007) demonstraram que variações climáticas globais já influenciavam os rendimentos agrícolas, com efeitos negativos do aquecimento recente sobre culturas estratégicas. Lobell, Schlenker e Costa-Roberts (2011) estimaram que as tendências climáticas desde 1980 reduziram a produção global de milho e trigo, mostrando que os impactos climáticos não se restringem a projeções futuras, mas já aparecem nas séries históricas de produção.

Ortiz-Bobea *et al.* (2021) ampliaram essa evidência ao estimarem redução de aproximadamente 21% no crescimento da produtividade agrícola global desde 1961 em decorrência da mudança climática antropogênica, com efeitos mais severos em regiões quentes, como África, América Latina e Caribe. Esse resultado é relevante para o Brasil, pois parte expressiva da produção de soja e milho ocorre em áreas tropicais e subtropicais, marcadas por temperaturas elevadas, irregularidade pluviométrica e exposição a eventos extremos. Assim, os impactos climáticos devem

ser compreendidos como fatores estruturais já incorporados à dinâmica agrícola, especialmente em países dependentes da agricultura de sequeiro.

No Brasil, esses efeitos são espacialmente heterogêneos. Silva *et al.* (2021), ao simularem cenários futuros para a soja em diferentes zonas agroclimáticas do país, demonstraram que os impactos sobre rendimento e produtividade da água variam conforme disponibilidade hídrica, temperatura, concentração de CO₂, características regionais e manejo. Zilli *et al.* (2020), com o modelo GLOBIOM-Brazil, indicaram que as mudanças climáticas podem reduzir a produção de soja e milho, especialmente no Matopiba, região formada pelos estados do Maranhão, Tocantins, Piauí e Bahia, além de favorecer deslocamentos da produção para áreas subtropicais.

Esses achados convergem com Rattis *et al.* (2021), segundo os quais 28% das terras agrícolas do Brasil já apresentam condições climáticas desfavoráveis à produção, com projeções de aumento para 51% até 2030 e 74% até 2060. Esse cenário indica risco de comprometimento de áreas cultivadas em estados estratégicos, como Mato Grosso, Goiás, Maranhão, Tocantins, Piauí e Bahia. Portanto, a produtividade agrícola não depende apenas de mecanização, insumos e melhoramento genético, mas também da estabilidade climática e da regularidade das chuvas em fases críticas do ciclo produtivo.

Além das mudanças climáticas globais, alterações no uso da terra afetam condições agroclimáticas locais e regionais. Spera, Winter e Partridge (2020) mostram que a conversão de áreas naturais no Cerrado pode reduzir os rendimentos do milho no Brasil, pois o desmatamento modifica fluxos de energia, evapotranspiração e padrões locais de temperatura. Batista, Duku e Hein (2023) demonstram que mudanças na precipitação induzidas pelo desmatamento reduziram os rendimentos do sistema soja-milho em estados da Amazônia e do Cerrado. Esses resultados reforçam o papel da vegetação nativa na regulação hídrica, na estabilidade climática regional e na resiliência agrícola.

Os impactos climáticos sobre os sistemas agrícolas repercutem na segurança alimentar e na estabilidade econômica. Os estudos do IPCC (2022, 2023) indicam que o aumento da temperatura média global intensifica riscos associados à alteração dos regimes de chuva, maior frequência de secas, ondas de calor, perda de geleiras, escassez hídrica e redução da biodiversidade. Esses efeitos reduzem a produtividade, elevam custos de produção e ampliam a vulnerabilidade econômica dos produtores rurais. No caso de *commodities* como soja e milho, perdas produtivas podem afetar

oferta e preços, dada sua importância para os mercados internacionais e para a segurança alimentar. Populações de baixa renda tendem a ser mais afetadas por destinarem maior parcela da renda à alimentação e terem menor capacidade de adaptação aos choques climáticos (IPCC, 2022, 2023; Jafino *et al.*, 2020; Crippa *et al.*, 2021).

Em um contexto de crescimento populacional e aumento da demanda por alimentos, torna-se urgente compreender os efeitos climáticos sobre culturas estratégicas. A FAO (2020) destaca a necessidade de aprofundar a análise dos impactos das mudanças climáticas sobre as culturas agrícolas mais relevantes. Essa preocupação é reforçada por projeções de longo prazo da organização, segundo as quais a produção global de alimentos deverá crescer substancialmente até meados do século para atender à demanda futura. Tchonkouang, Onyeaka e Nkoutchou (2024) acrescentam que as mudanças climáticas afetam produção, renda, preços, acesso aos alimentos, qualidade, segurança alimentar e resiliência das cadeias agroalimentares.

A literatura evidencia que os efeitos climáticos sobre a produção agrícola podem ser transmitidos aos mercados por redução da oferta, aumento dos custos e maior volatilidade dos preços. Moessner (2022), utilizando painel dinâmico das curvas de Phillips do Índice de Preços ao Consumidor de alimentos em 34 economias membros e candidatas da OCDE, entre 1985 e 2010, identificou relação não linear entre precipitação e preços dos alimentos. Kotz *et al.* (2024), ao analisarem mais de 27 mil observações mensais de índices de preços ao consumidor em escala global, verificaram que temperaturas elevadas aumentam de forma persistente a inflação de alimentos e a inflação cheia, com efeitos por até doze meses.

O aumento dos preços das *commodities* alimentares associado à variabilidade climática decorre da menor disponibilidade de grãos e do aumento dos custos de insumos e combustíveis (Yuan *et al.*, 2021; Santos; Alves, 2020). As secas extremas na Rússia e na Europa Oriental, por exemplo, foram o principal fator para o aumento de 30% nos preços do milho e do trigo em 2010 (Barriopedro *et al.*, 2011). Esse mecanismo de transmissão entre choques climáticos, redução da oferta e elevação de preços é relevante para soja e milho, cujos preços refletem condições produtivas locais, expectativas globais de oferta, estoques, comércio e risco climático.

Entre os fenômenos com maior capacidade de alterar condições agroclimáticas, destaca-se o El Niño, fase quente do El Niño-Oscilação Sul (ENOS),

caracterizada pelo aquecimento anômalo das águas superficiais do Pacífico tropical central e oriental, enfraquecimento dos ventos alísios e alterações na circulação atmosférica global. Em 2015-2016, foram registradas perdas agrícolas expressivas em países africanos, incluindo reduções de 68% na produção de algodão e quedas de 33% nas colheitas de milho e amendoim em determinados contextos nacionais (Braimoh *et al.*, 2018). Na Zâmbia, Alfani *et al.* (2019) estimaram que a seca associada ao El Niño reduziu em torno de 20% os rendimentos do milho e aproximadamente 37% da renda per capita rural.

Na África Oriental e Meridional, o El Niño tem agravado pobreza e insegurança alimentar, dada a dependência das populações rurais em relação à agricultura de sequeiro. Na Zâmbia, entre 2015 e 2016, secas e inundações associadas ao fenômeno resultaram em queda de 10% na produção de milho, elevando a pobreza em 1% e a pobreza extrema em 1,9% (Braimoh *et al.*, 2018). Yahyaei, Kitsios e De Mello (2024) demonstraram que a variabilidade associada ao ENOS também pode ser transmitida aos mercados financeiros de *commodities* agrícolas, ampliando a incerteza de preços de trigo, milho, arroz e soja.

Diversos estudos empíricos investigam os efeitos das variáveis climáticas sobre mercados agrícolas e indicadores econômicos. Solaymani (2018), por meio de modelo de equilíbrio geral computável aplicado à Malásia, constatou que variações de temperatura e precipitação reduzem a oferta de produtos agrícolas, pressionam os preços dos alimentos e diminuem o bem-estar das famílias, especialmente nas áreas rurais. Hagos (2018), com modelos de séries temporais para a Etiópia, identificou que um aumento de 1°C na temperatura elevou os preços de produtos agrícolas, incluindo aproximadamente 80% na cevada, 186% no milho e 60% no trigo. Na Tunísia, Zaid e Zouabi (2015) e Attiaoui e Boufateh (2019), com testes de cointegração em painel, concluíram que temperatura e precipitação afetam negativamente a produção agrícola, sobretudo a produtividade dos cereais, contribuindo para a elevação dos preços.

Por outro lado, Benhin (2008), com abordagem ricardiana aplicada à África do Sul, identificou que aumentos na temperatura média anual e na precipitação estavam associados a elevações na receita líquida agrícola. Esse resultado deve ser interpretado com cautela, pois os efeitos climáticos sobre a renda variam conforme região, cultura, disponibilidade hídrica, capacidade de adaptação, acesso à tecnologia e estrutura de mercado. Assim, evidências positivas em determinados contextos não

anulam efeitos adversos observados em regiões tropicais ou em sistemas dependentes da regularidade pluviométrica.

No Brasil, a redução da produtividade em regiões agrícolas estratégicas tem sido associada à irregularidade das chuvas, sobretudo na fase inicial de crescimento das culturas. A escassez hídrica e o aumento das temperaturas comprometem o desenvolvimento das lavouras, ampliam a vulnerabilidade produtiva e podem pressionar preços quando há perdas significativas de safra. Além disso, a redução da oferta de grãos, combinada à elevação dos custos de irrigação, readequação produtiva e controle de pragas e doenças, impõe desafios aos produtores, especialmente os de menor escala (Embrapa, 2023). Esses custos tendem a ser repassados aos preços finais. Qiao, Cheng e Ali (2023) acrescentam que choques climáticos sobre a produtividade da soja nos principais países produtores podem se propagar internacionalmente pelo comércio, afetando oferta, preços e segurança alimentar global.

Em síntese, a literatura demonstra que as mudanças climáticas afetam produtividade agrícola, cadeias de suprimentos, renda rural, preços das *commodities* e segurança alimentar. Estudos empíricos indicam que eventos extremos têm aumentado a frequência e a intensidade dos choques de oferta agrícola, especialmente em países em desenvolvimento, pressionando rendimentos, preços e renda rural (Bailey *et al.*, 2015; Newell; Prest; Sexton, 2021). Apesar do avanço das pesquisas, ainda são escassos os estudos que examinam, de maneira integrada, os efeitos de temperatura e precipitação sobre a produtividade e a formação dos preços do milho e da soja no Brasil. Essa lacuna é relevante porque grande parte da literatura analisa separadamente produtividade agrícola, preços de *commodities*, inflação de alimentos ou segurança alimentar, enquanto a dinâmica brasileira exige uma abordagem integrada entre clima, produção, mercado e transmissão econômica.

2.2 Modelos de Paineis e Economia do Clima

A literatura sobre mudanças climáticas e agricultura avançou nas últimas décadas, evoluindo de abordagens agregadas e predominantemente lineares para estratégias econométricas capazes de captar heterogeneidade espacial, variações temporais do clima e diferenças na sensibilidade produtiva entre regiões. Esse avanço metodológico ampliou a compreensão dos impactos econômicos das mudanças climáticas sobre a produtividade agrícola, fornecendo evidências relevantes para

subsidiar políticas públicas, estratégias de adaptação e planejamento do setor agropecuário (Carleton; Hsiang, 2016; Hsiang *et al.*, 2017; Burke; Hsiang; Miguel, 2015; Wing; De Cian; Mistry, 2021).

Nessa perspectiva, Mendelsohn, Nordhaus e Shaw (1994) demonstraram que o valor da terra incorpora, em equilíbrio, os efeitos de longo prazo das condições climáticas, bem como os ajustes produtivos realizados pelos agricultores em resposta às características ambientais locais. Essa abordagem representou um importante avanço ao reconhecer que os agentes econômicos podem adaptar suas decisões produtivas às condições climáticas vigentes. Contudo, por se apoiar em comparações entre unidades espaciais distintas, a abordagem ricardiana exige cautela na interpretação causal, pois parte das diferenças observadas entre regiões pode decorrer de fatores estruturais não climáticos, como qualidade do solo, infraestrutura, acesso a mercados, tecnologia e características institucionais (Bareille; Chakir, 2023; Mendelsohn; Nordhaus; Shaw, 1994).

Bareille e Chakir (2023), ao proporem uma abordagem *repeat-Ricardian* com efeitos fixos ao nível da parcela agrícola, reforçam essa limitação ao mostrar que características omitidas da terra podem gerar viés relevante nas estimativas ricardianas tradicionais. Assim, embora a abordagem ricardiana seja importante para captar mecanismos de adaptação de longo prazo, sua capacidade de identificação depende da qualidade dos controles observáveis e da possibilidade de separar o efeito climático de demais características estruturais das regiões analisadas.

Em razão dessas limitações, estudos posteriores passaram a explorar com maior intensidade modelos de dados em painel, baseados em variações temporais de temperatura e precipitação dentro de uma mesma unidade geográfica (Deschênes; Greenstone, 2007; Dell; Jones; Olken, 2014; Blanc; Schlenker, 2017). Essa estratégia não elimina todos os problemas de identificação, mas permite reduzir parte do viés associado a diferenças permanentes entre regiões, ao controlar características não observadas que permanecem relativamente constantes ao longo do tempo, como atributos edafoclimáticos, localização, relevo, infraestrutura produtiva e aptidão agrícola.

Nesse contexto, Deschênes e Greenstone (2007) contribuíram para consolidar o uso de modelos de painel na literatura de economia do clima ao utilizarem flutuações anuais de temperatura e precipitação para estimar os impactos climáticos sobre a produção agrícola. A principal contribuição dessa estratégia é explorar variações

climáticas dentro de uma mesma unidade espacial ao longo do tempo, reduzindo a influência de diferenças permanentes entre regiões. Essa abordagem permite controlar características fixas não observadas, como qualidade do solo, localização geográfica, relevo e aptidão agrícola, que poderiam influenciar simultaneamente produtividade e condições de produção.

A literatura posterior reforçou a importância, mas também os limites, dessa estratégia metodológica. Dell, Jones e Olken (2014) argumentam que uma parcela crescente da literatura de economia do clima tem utilizado métodos de painel para examinar como variações de temperatura, precipitação e eventos climáticos extremos influenciam diferentes desfechos econômicos. Blanc e Schlenker (2017), por sua vez, destacam que os modelos de painel são particularmente úteis em estudos agrícolas porque permitem comparar desvios climáticos em relação às condições médias de uma mesma unidade espacial. Dessa forma, os modelos de dados em painel não devem ser tratados como a única ou necessariamente a principal ferramenta de análise dos impactos econômicos das mudanças climáticas, mas como uma estratégia empírica influente e adequada quando o objetivo é explorar variações climáticas ao longo do tempo dentro de unidades espaciais observadas repetidamente.

No setor agrícola, essa característica é particularmente relevante, uma vez que fatores como qualidade do solo, relevo, infraestrutura, disponibilidade de recursos naturais e nível tecnológico tendem a permanecer relativamente estáveis ao longo do tempo, podendo influenciar simultaneamente a produtividade e as condições de produção. Dessa forma, os modelos de painel permitem controlar parte da heterogeneidade espacial não observada e estimar a associação entre variações climáticas contemporâneas e desempenho agrícola, produzindo estimativas mais consistentes dos impactos da temperatura e da precipitação (Blanc; Schlenker, 2017; Emediegwu; Wossink; Hall, 2022).

Os modelos de efeitos fixos tornaram-se especialmente difundidos nessa literatura. Segundo Wooldridge (2010), essa especificação é adequada quando existem características não observadas correlacionadas com as variáveis explicativas do modelo, permitindo controlar a heterogeneidade individual e produzir estimativas consistentes dos parâmetros de interesse. Assim, ao explorar a variação temporal das condições climáticas dentro de cada unidade de análise, os modelos de efeitos fixos possibilitam estimar de maneira mais robusta os impactos das mudanças climáticas sobre a produtividade agrícola, desde que os pressupostos econométricos do modelo

sejam avaliados e que problemas como heterocedasticidade, autocorrelação, dependência temporal ou espacial e possível endogeneidade sejam adequadamente considerados (Wooldridge, 2010; Blanc; Schlenker, 2017).

A distinção entre clima e tempo meteorológico também é relevante para esta estratégia empírica. Variações climáticas de curto prazo captam choques meteorológicos durante o ciclo produtivo, enquanto médias ou tendências de longo prazo podem refletir condições agroclimáticas estruturais e respostas adaptativas. Por isso, a interpretação dos coeficientes estimados em modelos de painel deve reconhecer se as variáveis captam flutuações anuais, desvios em relação à média histórica ou mudanças climáticas persistentes ao longo do tempo.

Diante dessas vantagens e limitações metodológicas, a presente pesquisa utiliza modelos de dados em painel para analisar os impactos das variáveis climáticas sobre a produtividade da soja e do milho no Brasil no período de 2012 a 2024. A definição da especificação mais apropriada não decorre de uma escolha apriorística por efeitos fixos, mas da comparação entre alternativas econométricas e da realização de testes de especificação, como testes para efeitos fixos, efeitos aleatórios e o teste de Hausman, além de diagnósticos adicionais relacionados à adequação dos resíduos e à robustez das estimativas. Essa estratégia é consistente com a literatura de economia do clima e fornece a base empírica necessária para investigar os efeitos médios das variáveis climáticas, as possíveis não linearidades e os mecanismos de adaptação climática analisados nas seções subsequentes.

2.3 Não linearidade climática

A hipótese de que os efeitos climáticos sobre a produtividade agrícola são lineares tem sido amplamente questionada pela literatura. Schlenker e Roberts (2009) demonstraram que culturas como milho, soja e algodão apresentam ganhos de produtividade até determinados limiares térmicos, mas sofrem perdas expressivas quando expostas a temperaturas acima desses limites. Os autores identificaram que os rendimentos aumentam até aproximadamente 29°C para o milho, 30 °C para a soja e 32 °C para o algodão, declinando após esses pontos críticos. Essa evidência é consistente com Burke, Hsiang e Miguel (2015), que demonstram a existência de uma relação não linear entre temperatura e produção econômica, e com Schauburger *et al.* (2017), que identificam respostas negativas de culturas agrícolas a altas temperaturas.

Essa evidência é relevante para estudos sobre agricultura e mudanças climáticas, pois indica que médias anuais de temperatura podem mascarar os efeitos prejudiciais de episódios de calor extremo. Em termos agronômicos e econométricos, isso significa que o efeito marginal da temperatura sobre a produtividade não é constante: temperaturas moderadas podem favorecer o desenvolvimento das culturas, enquanto temperaturas acima de determinados limiares fisiológicos podem gerar perdas desproporcionais de rendimento. Assim, a inclusão de termos quadráticos, variáveis de *threshold* ou medidas de exposição a temperaturas críticas permite captar efeitos assimétricos e não proporcionais das variáveis climáticas sobre a produtividade (Schlenker; Roberts, 2009; Hogan; Schlenker, 2024; Schaubberger *et al.*, 2017).

A literatura também enfatiza que a forma de mensurar a exposição climática afeta a identificação dos danos sobre a produtividade agrícola. Hogan e Schlenker (2024) mostram que dados climáticos diários são mais adequados do que médias mensais ou sazonais para captar os efeitos prejudiciais dos extremos de temperatura sobre os rendimentos agrícolas, pois a agregação temporal pode ocultar exposições críticas durante fases específicas do ciclo produtivo. Essa evidência é importante para culturas como soja e milho, sensíveis à ocorrência de calor extremo e déficit hídrico em fases fenológicas específicas (Hogan; Schlenker, 2024; Schaubberger *et al.*, 2017; Schmitt *et al.*, 2022).

Schaubberger *et al.* (2017) reforçam essa interpretação ao demonstrarem que altas temperaturas exercem efeitos negativos consistentes sobre milho, soja e trigo nos Estados Unidos. Os autores indicam que dias acima de 30 °C reduzem os rendimentos de milho e soja em condições de sequeiro, o que evidencia a importância de considerar a interação entre calor extremo e disponibilidade hídrica. Essa distinção é relevante porque sistemas irrigados e de sequeiro podem apresentar diferentes níveis de exposição e capacidade de amortecimento dos choques térmicos (Schaubberger *et al.*, 2017; Heino *et al.*, 2023; Schmitt *et al.*, 2022).

Gammans, Mérel e Ortiz-Bobea (2017) também identificaram impactos negativos do aquecimento sobre a produtividade de cereais, reforçando que os efeitos climáticos tendem a se intensificar em níveis mais elevados de temperatura. Ao analisarem séries históricas de trigo e cevada na França, os autores demonstram que a exposição ao calor durante a estação de crescimento pode reduzir de forma expressiva os rendimentos, especialmente em cenários de aquecimento mais intenso.

Essa literatura justifica a incorporação de modelos não lineares na análise da produtividade agrícola, especialmente em países tropicais, nos quais as culturas frequentemente operam próximas aos limites fisiológicos de tolerância térmica (Gammans; Mérel; Ortiz-Bobea, 2017; Burke; Hsiang; Miguel, 2015; Rezaei *et al.*, 2023).

Em escala global, Ray *et al.* (2015) mostram que a variabilidade climática explica parcela expressiva da variabilidade dos rendimentos agrícolas de culturas como milho, arroz, trigo e soja. Essa evidência amplia a discussão ao indicar que temperatura e precipitação, isoladamente ou em interação, contribuem para oscilações produtivas relevantes em diferentes regiões agrícolas. De modo complementar, Rezaei *et al.* (2023) sintetizam evidências de que o aquecimento, a disponibilidade hídrica e a concentração atmosférica de CO₂ afetam os rendimentos de culturas básicas, embora os possíveis benefícios do CO₂ possam ser compensados ou anulados por calor e seca (Ray *et al.*, 2015; Rezaei *et al.*, 2023; Lesk; Anderson; Konar, 2022).

Além da temperatura, a precipitação também pode apresentar comportamento não linear. Níveis adequados de chuva favorecem o desenvolvimento das culturas, enquanto a escassez hídrica compromete a germinação, o florescimento e o enchimento de grãos. Por outro lado, precipitações excessivas podem causar encharcamento do solo, erosão, perda de nutrientes e dificuldades operacionais no plantio e na colheita. Assim, tanto o déficit quanto o excesso de chuvas podem reduzir o rendimento agrícola, justificando a inclusão de termos quadráticos de precipitação nos modelos econométricos (Heino *et al.*, 2023; Liu; Mishra; Ray, 2020; Hu *et al.*, 2024).

Do ponto de vista empírico, a modelagem da precipitação exige atenção semelhante à da temperatura, pois seus efeitos podem seguir uma relação em formato de “U invertido”: níveis intermediários tendem a favorecer a produtividade, enquanto valores muito baixos ou muito elevados podem provocar perdas. Essa estrutura é importante para culturas de sequeiro, como soja e milho em grande parte do Brasil, cuja produtividade depende não apenas do volume total de chuvas, mas também de sua distribuição temporal ao longo do ciclo produtivo. Portanto, a análise da precipitação deve considerar tanto a quantidade acumulada quanto a ocorrência de déficits ou excessos hídricos em momentos críticos do desenvolvimento das culturas (Liu; Mishra; Ray, 2020; Heino *et al.*, 2023; Schmitt *et al.*, 2022).

A literatura recente também destaca que os impactos climáticos podem ser compostos, isto é, resultantes da interação entre calor extremo, seca e excesso de umidade. Lesk, Anderson e Konar (2022) argumentam que extremos combinados de calor e umidade afetam os rendimentos agrícolas por meio de interações fisiológicas entre temperatura, água e desenvolvimento das culturas. Heino *et al.* (2023), por sua vez, mostram que eventos simultaneamente quentes e secos apresentam efeitos negativos consistentes sobre os rendimentos globais de trigo, milho, soja e arroz. Essas evidências indicam que a análise isolada da temperatura ou da precipitação pode subestimar os danos quando os choques climáticos ocorrem conjuntamente (Lesk; Anderson; Konar, 2022; Heino *et al.*, 2023; Schmitt *et al.*, 2022).

No caso brasileiro, a discussão sobre não linearidade climática é especialmente relevante porque a produção de soja e milho ocorre majoritariamente em sistemas dependentes da regularidade das chuvas e sujeitos à intensificação de ondas de calor, déficit hídrico e alterações nos regimes pluviométricos. Batista, Duku e Hein (2023) mostram que mudanças na precipitação associadas ao desmatamento podem reduzir os rendimentos do sistema soja-milho no Brasil, evidenciando que alterações hidrológicas regionais afetam diretamente a produtividade agrícola. Prudente Junior *et al.* (2024), ao desenvolverem um modelo de previsão para o milho safrinha no Brasil, também demonstram que indicadores agrometeorológicos durante o ciclo produtivo explicam parcela relevante da variabilidade interanual da produção (Batista; Duku; Hein, 2023; Prudente Junior *et al.*, 2024; Rattis *et al.*, 2021).

Dessa forma, a incorporação de termos quadráticos, funções de resposta não lineares, *thresholds* ou medidas de exposição a extremos climáticos permite representar de maneira mais adequada a relação entre clima e produtividade agrícola. Essa estratégia é relevante porque os efeitos da temperatura e da precipitação não são necessariamente constantes ao longo de sua distribuição. Em termos econométricos, isso significa que modelos estritamente lineares podem subestimar perdas em condições extremas e superestimar efeitos em faixas climáticas moderadas, especialmente quando a produção agrícola ocorre próxima aos limites fisiológicos das culturas (Schlenker; Roberts, 2009; Hogan; Schlenker, 2024; Hu *et al.*, 2024).

Assim, no contexto desta pesquisa, a hipótese de não linearidade climática é central para avaliar se a produtividade da soja e do milho no Brasil responde de forma diferenciada a distintos níveis de temperatura e precipitação. A consideração dessas

não linearidades permite investigar não apenas o efeito médio das variáveis climáticas, mas também a existência de limiares críticos a partir dos quais os impactos sobre a produtividade se tornam mais intensos (Schlenker; Roberts, 2009; Hogan; Schlenker, 2024; Rezaei *et al.*, 2023).

2.4 Adaptação climática

A adaptação climática constitui um dos temas centrais da literatura sobre agricultura e mudanças climáticas. A adaptação pode ser compreendida como o conjunto de respostas tecnológicas, produtivas, institucionais e gerenciais que reduzem a sensibilidade dos sistemas agrícolas aos choques climáticos. Entre essas estratégias, destacam-se o uso de cultivares mais resistentes ao calor e à seca, a alteração do calendário agrícola, a expansão da irrigação, o manejo conservacionista do solo, a agricultura de precisão e a diversificação produtiva (Howden *et al.*, 2007; IPCC, 2022; Cobourn; Ignaciuk, 2025).

No setor agrícola, a adaptação pode assumir diferentes formas, desde ajustes incrementais no manejo produtivo até transformações mais profundas nos sistemas de produção. Ajustes incrementais incluem mudanças no calendário de plantio, escolha de cultivares, manejo da irrigação e adoção de práticas conservacionistas. Já estratégias transformativas envolvem mudanças mais amplas na organização produtiva, na alocação de recursos, na diversificação de culturas e na reorganização espacial da produção agrícola. Essa distinção é importante porque nem toda resposta adaptativa possui a mesma capacidade de reduzir perdas climáticas no longo prazo (Howden *et al.*, 2007; IPCC, 2022; Cobourn; Ignaciuk, 2025).

A literatura mostra que a adaptação pode reduzir parte dos impactos negativos das mudanças climáticas, mas dificilmente elimina integralmente os danos sobre a produtividade agrícola. Challinor *et al.* (2014), em uma meta-análise com mais de 1.700 simulações, mostram que adaptações em nível de cultura podem elevar os rendimentos simulados em média entre 7% e 15%, embora os efeitos variem por cultura e sejam mais efetivos para trigo e arroz do que para milho. Esse resultado demonstra que a adaptação possui potencial de mitigação produtiva, mas seus efeitos dependem da cultura analisada, da região, do tipo de prática adotada e da intensidade do aquecimento (Challinor *et al.*, 2014; Howden *et al.*, 2007; Hasegawa *et al.*, 2022).

Burke e Emerick (2016) analisaram evidências de adaptação na agricultura dos Estados Unidos e demonstraram que, embora existam mecanismos adaptativos, estes não necessariamente compensam integralmente os danos causados pelo

aquecimento. Essa conclusão é importante porque impede interpretações excessivamente otimistas dos coeficientes de adaptação: a redução da sensibilidade da produtividade ao clima pode indicar algum grau de ajuste, mas não significa eliminação completa dos prejuízos climáticos. Assim, a adaptação deve ser interpretada como mecanismo parcial de redução da vulnerabilidade, e não como substituto para políticas de mitigação, inovação tecnológica e gestão de riscos climáticos (Burke; Emerick, 2016; Wing; De Cian; Mistry, 2021; Hultgren *et al.*, 2025).

Essa evidência é reforçada por estudos recentes em escala global. Wing, De Cian e Mistry (2021), ao utilizarem um painel global de rendimentos agrícolas em grade e um modelo econométrico dinâmico, distinguem respostas de curto e longo prazo dos produtores aos choques climáticos. Os autores mostram que a adaptação histórica modera apenas parcialmente os efeitos negativos do aquecimento sobre os rendimentos agrícolas, indicando que a capacidade adaptativa observada não elimina integralmente os danos climáticos projetados. De forma semelhante, Hultgren *et al.* (2025) estimam que a adaptação e o crescimento da renda reduzem parte das perdas globais projetadas, mas não impedem perdas residuais relevantes para culturas alimentares estratégicas (Wing; De Cian; Mistry, 2021; Hultgren *et al.*, 2025; Challinor *et al.*, 2014).

A adaptação também pode ocorrer por meio da realocação do uso da terra e da mudança na composição das culturas. Cui (2020), ao analisar padrões de cultivo de milho e soja nos Estados Unidos, mostra que mudanças de longo prazo em temperatura e precipitação podem induzir ajustes na área plantada, indicando que a adaptação agrícola ocorre não apenas via produtividade, mas também por meio de substituição de culturas e redistribuição espacial da produção. Essa perspectiva amplia a compreensão da adaptação, pois evidencia que os produtores podem responder ao clima alterando técnicas de manejo, calendários agrícolas, cultivares e decisões de alocação produtiva (Cui, 2020; Howden *et al.*, 2007; Wing; De Cian; Mistry, 2021).

Outra dimensão importante da adaptação refere-se à alteração dos calendários agrícolas e à escolha de cultivares com ciclos produtivos mais adequados às novas condições climáticas. Minoli *et al.* (2022) demonstram que a adaptação oportuna dos períodos de cultivo, por meio do ajuste de datas de semeadura e cultivares, pode elevar os rendimentos globais em aproximadamente 12%, reduzindo parte dos impactos negativos das mudanças climáticas. Esse resultado reforça a importância de

considerar o momento da exposição climática no ciclo produtivo, especialmente em culturas como soja e milho, cujos rendimentos dependem da coincidência entre fases fenológicas críticas, disponibilidade hídrica e temperatura adequada (Minoli *et al.*, 2022; Hasegawa *et al.*, 2022; Howden *et al.*, 2007).

Além dos ajustes dentro da propriedade, a adaptação pode ocorrer por meio da migração espacial das culturas. Sloat *et al.* (2020) mostram que mudanças na distribuição espacial de culturas de sequeiro, como milho, trigo, arroz e soja, já moderaram parte dos efeitos adversos do aquecimento em algumas regiões. De forma complementar, Rising e Devineni (2020) demonstram que a substituição de culturas e a realocação espacial da produção podem reduzir perdas agrícolas projetadas sob cenários de aquecimento, embora tais estratégias também apresentem limites econômicos, institucionais, logísticos e ambientais. Essas evidências indicam que a adaptação climática não se restringe ao manejo agrônomo, mas envolve decisões espaciais e econômicas sobre onde, quando e o que produzir (Sloat *et al.*, 2020; Rising; Devineni, 2020; Cui, 2020).

No Brasil, essa discussão é importante porque a produção de soja e milho está associada a sistemas de sequeiro, ao regime de chuvas e à viabilidade da dupla safra. Pires *et al.* (2016) mostram que os sistemas brasileiros de dupla safra são sensíveis ao encurtamento da estação chuvosa e à redução da precipitação no início do calendário agrícola, de modo que o simples ajuste de datas de plantio pode reduzir perdas da soja, mas também comprometer a possibilidade de implantação da segunda safra. Assim, a adaptação agrícola no Brasil envolve um *trade-off* importante entre proteger a produtividade da primeira cultura e preservar a janela agrônoma da segunda cultura (Pires *et al.*, 2016; Carauta *et al.*, 2021; Brumatti *et al.*, 2020).

Carauta *et al.* (2021) reforçam esse ponto ao avaliarem os impactos potenciais das mudanças climáticas sobre a rentabilidade de sistemas agrícolas em Mato Grosso. Os autores mostram que a redução da precipitação anual, o encurtamento da estação chuvosa e alterações nas datas de início e término das chuvas podem comprometer a rentabilidade dos sistemas de dupla safra, reduzindo uma das principais vantagens comparativas da agricultura brasileira. Essa evidência é importante, pois conecta adaptação climática, produtividade agrícola, rentabilidade e organização temporal dos sistemas soja-milho no Brasil (Carauta *et al.*, 2021; Pires *et al.*, 2016; Brumatti *et al.*, 2020).

No campo empírico, a adaptação pode ser investigada por meio de interações entre variáveis climáticas e tendência temporal, permitindo avaliar se os impactos da temperatura e da precipitação sobre a produtividade agrícola se alteram ao longo do tempo. Caso o efeito negativo da temperatura diminua ao longo dos anos, pode-se interpretar esse resultado como evidência parcial de adaptação, desde que se reconheçam as limitações da identificação causal e a possibilidade de que essa redução decorra de fatores não observados, como mudança tecnológica, expansão da irrigação, deslocamento regional da produção, alteração de cultivares ou mudanças na composição das áreas cultivadas (Burke; Emerick, 2016; Wing; De Cian; Mistry, 2021; Blanc; Schlenker, 2017).

Entretanto, a identificação empírica da adaptação exige cautela. Modelos baseados em interações entre clima e tendência temporal podem captar redução da sensibilidade produtiva ao clima, mas não permitem afirmar automaticamente que essa redução decorre exclusivamente de adaptação deliberada dos produtores. Em contextos agrícolas marcados por mudanças tecnológicas, expansão territorial, melhoria genética, políticas públicas, crédito rural e alterações de mercado, a adaptação deve ser tratada como hipótese empírica e não como pressuposto teórico previamente confirmado (Burke; Emerick, 2016; Wing; De Cian; Mistry, 2021; Blanc; Schlenker, 2017).

Além disso, Hasegawa *et al.* (2022), ao consolidarem uma base global de simulações de impactos das mudanças climáticas sobre milho, arroz, soja e trigo, mostram que os impactos médios projetados são menos negativos quando medidas de adaptação são consideradas, embora permaneçam perdas relevantes para culturas estratégicas. Essa evidência reforça que a adaptação deve ser incorporada às análises de produtividade agrícola, mas sem assumir que ela neutraliza integralmente os efeitos adversos da temperatura, da precipitação e dos eventos extremos (Hasegawa *et al.*, 2022; Challinor *et al.*, 2014; Hultgren *et al.*, 2025).

Portanto, a literatura sustenta que a análise da produtividade agrícola sob mudanças climáticas deve considerar simultaneamente os efeitos médios do clima, a presença de não linearidades e os possíveis mecanismos de adaptação. Essa abordagem é especialmente relevante para a soja e o milho no Brasil, culturas de elevada importância econômica e expostas a condições climáticas heterogêneas, eventos extremos e mudanças nos regimes de temperatura e precipitação. Ao reconhecer que a adaptação pode reduzir parte dos danos, mas não os eliminar, a

literatura também reforça a necessidade de estimativas empíricas cautelosas, capazes de distinguir sensibilidade climática, mudança tecnológica, reorganização espacial da produção e respostas adaptativas dos produtores (Burke; Emerick, 2016; Wing; De Cian; Mistry, 2021; Hultgren *et al.*, 2025).

Dessa forma, esta seção encerra a revisão de literatura ao evidenciar que os impactos climáticos sobre a produtividade agrícola não devem ser analisados apenas como efeitos médios e lineares da temperatura e da precipitação. A literatura indica que esses impactos dependem de relações não lineares, limiares críticos, eventos extremos, heterogeneidade espacial e capacidade adaptativa dos produtores. Assim, a presente pesquisa se insere nesse debate ao investigar os efeitos das variáveis climáticas sobre a produtividade da soja e do milho no Brasil, considerando a possibilidade de respostas não lineares e de adaptação ao longo do tempo.

Assim, a presente pesquisa contribui para a literatura sobre economia climática aplicada à agricultura ao analisar se a produtividade agrícola brasileira apresenta respostas não lineares à temperatura e à precipitação, se existem limiares climáticos críticos e se há evidências de adaptação ao longo do período analisado. A análise concentra-se em culturas estratégicas, como soja e milho, cuja importância econômica contrasta com a crescente exposição à variabilidade climática e à ocorrência de eventos extremos.

Na tabela 1 apresenta-se a comparação dos riscos com o aumento das temperaturas na terra.

Tabela 1- Comparação dos riscos com o aumento das temperaturas da terra.

Categoria	1,5°C	2°C	3°C	1,5°C vs 2°C	1,5°C vs 3°C
Seca					
População em zona árida exposta	0,95 bilhão de pessoas	1,15 bilhão de pessoas	1,29 bilhão de pessoas	200 milhões a mais	340 milhões a mais
Segurança Alimentar					
Custos de adaptação e danos	US\$ 63 bilhões	US\$ 80 bilhões	US\$ 125 bilhões	US\$ 17 bilhões a mais	US\$ 65 bilhões a mais
Calor Extremo					
Dias acima de 35°C	De 45% para 58%	De 52% para 68%	De 66% para 87%	1,2 vezes pior	1,5 vezes pior
Ondas de calor no sul da África	2-4 vezes	4-8 vezes	8-12 vezes	2 vezes pior	3,3 vezes pior
Inundações					
População global exposta	24%	30%	-	1,3 vezes pior	-

Fonte: Adaptado do IPCC (2023).

Conforme os dados apresentados no Tabela 1, observa-se que os impactos das mudanças climáticas se intensificam à medida que a elevação da temperatura global ultrapassa o limite de 1,5 °C, aproximando-se dos cenários de 2 °C e 3 °C. Esses cenários projetam uma escalada dos riscos associados à escassez de recursos naturais, à segurança alimentar, à saúde humana e à integridade dos ecossistemas. As projeções reforçam que limitar o aquecimento global a 1,5 °C não é apenas uma questão ambiental, mas também econômica e social.

Adicionalmente, o IPCC (2023) destaca que o aumento da temperatura global já tem provocado alterações significativas no regime de chuvas, maior frequência de secas e intensificação das ondas de calor. Temperaturas superiores a 35 °C, associadas à redução das precipitações, agravam a escassez hídrica e comprometem a produtividade agrícola. Segundo o relatório, eventos de calor extremo podem ocorrer de duas a quatro vezes por ano, favorecendo a ocorrência de incêndios e ampliando em até 24% a população exposta a inundações, percentual que poderá alcançar 30% caso o aquecimento global atinja 2 °C (IPCC, 2023).

Além disso, o aumento da temperatura média global em 1,5 °C poderá provocar o desaparecimento de diversas geleiras, comprometendo o abastecimento de água para milhões de pessoas. A Organização das Nações Unidas (ONU, 2015) estima que cerca de 350 milhões de pessoas poderão enfrentar escassez hídrica até 2030. O IPCC (2022) também alerta que esse nível de aquecimento poderá colocar em risco de extinção até 14% das espécies terrestres, evidenciando que as mudanças climáticas geram impactos ambientais, sociais e econômicos de longo prazo.

No âmbito econômico, o IPCC (2023) indica que um aumento de 1 °C na temperatura média global pode elevar em até 53% os custos da produção agrícola, reduzindo a rentabilidade da atividade rural. Parte desse aumento tende a ser repassada aos consumidores por meio da elevação dos preços dos alimentos (Crippa *et al.*, 2021). Nesse contexto, torna-se relevante analisar os efeitos das mudanças climáticas sobre os preços de commodities agrícolas, como a soja e o milho, devido à sua importância para o comércio internacional e para a segurança alimentar.

As mudanças climáticas podem afetar especialmente as populações de baixa renda, que destinam uma parte significativa de sua renda à alimentação (IPCC, 2022; Barbieri *et al.*, 2010). Segundo Jafino *et al.* (2020), até 2030, mais de 130 milhões de pessoas podem ser empurradas para a pobreza em decorrência dos impactos

climáticos, e cerca de 200 milhões podem ser forçadas a migrar até 2050, ampliando as vulnerabilidades sociais.

O estudo utilizado foram análise descritiva e quantitativa que revelaram que os países da amostra passaram por vários eventos de mudanças climáticas com intensidade crescente como 2019, o que afetou os choques de oferta medidos com base na quantidade de chuvas e na inflação dos preços dos alimentos. O que apontam que as mudanças climáticas vêm reduzindo os rendimentos e a renda em áreas rurais de países em desenvolvimento, o que reforça a necessidade de políticas públicas para garantir a subsistência das populações mais vulneráveis (Bailey *et al.*, 2015; Newell; Prest; Sexton, 2021).

Contudo, mesmo diante desses esforços, os preços dos alimentos seguem em alta, refletindo tanto a instabilidade climática quanto a complexidade dos mercados agrícolas globais. Assim, a compreensão das interações entre temperatura, precipitação e preços agrícolas se mostra essencial para a formulação de políticas públicas, especialmente em países produtores e exportadores de *commodities* como soja e milho.

3. DADOS E METODOLOGIA

Este capítulo apresenta os procedimentos metodológicos adotados para analisar os impactos das variáveis climáticas sobre a produtividade agrícola da soja e do milho no Brasil, no período de 2012 a 2024. Inicialmente, são descritas as fontes de dados, a construção da base de dados em painel e as variáveis utilizadas na pesquisa. Em seguida, são apresentadas as especificações econométricas empregadas para estimar os efeitos da temperatura e da precipitação sobre a produtividade agrícola, contemplando uma especificação linear (modelo *baseline*), um modelo de não linearidade climática e um modelo de adaptação climática.

Posteriormente, são descritos os procedimentos utilizados para a seleção do estimador mais adequado, bem como os testes econométricos empregados para avaliar a consistência dos modelos estimados. Por fim, apresentam-se os critérios adotados para a avaliação da robustez dos resultados.

A estratégia empírica foi desenvolvida considerando a estrutura longitudinal dos dados, permitindo explorar simultaneamente a variação temporal e a heterogeneidade entre as unidades analisadas. Essa abordagem possibilita controlar fatores não observados que permanecem constantes ao longo do tempo e que podem influenciar a produtividade agrícola, reduzindo potenciais vieses de estimação decorrentes da omissão de características estruturais específicas de cada unidade de análise

3.1 Estratégia empírica

Para mensurar os efeitos climáticos extremos sobre o rendimento físico das culturas da soja e do milho, a metodologia utilizada seguirá três etapas, assim como em Deng *et al.* (2010). A primeira refere-se a uma análise de regressão em painel que dentre outros aspectos permitiu identificar os impactos dos eventos climáticos sobre o regime precipitação e os níveis de temperatura para o país. Na segunda etapa, também serão estimadas regressões em painel para traçar a relação existente entre os níveis de precipitação e temperatura e a produtividade das culturas de soja e de milho no Brasil. Finalmente, na etapa final, buscou-se computar quais foram as perdas e ou ganhos em termos de produtividade, apresentado pelo país levando em consideração a quantidade de eventos climáticos extremos.

Para analisar os impactos dos elementos climáticos na produtividade da soja e do milho, foram especificados os modelos *baseline*, não linearidade e de adaptação:

Figura 1- Fluxograma da estratégia empírica e econométrica da pesquisa.



Fonte: Elaboração do autor (2026).

3.2 Especificação dos modelos econométricos

A estratégia econométrica foi desenvolvida para investigar os efeitos das variáveis climáticas sobre a produtividade agrícola da soja e do milho, considerando três dimensões complementares da relação entre clima e produção agrícola. Inicialmente, foi estimado um modelo linear de referência (*baseline*), destinado a mensurar os efeitos médios da temperatura e da precipitação sobre o rendimento agrícola. Em seguida, estimou-se um modelo de não linearidade climática, permitindo verificar se esses efeitos variam conforme a intensidade das condições climáticas observadas. Por fim, foi especificado um modelo de adaptação climática, com o

objetivo de avaliar se a sensibilidade da produtividade agrícola às variações de temperatura sofreu alterações ao longo do período analisado.

Todas as especificações econométricas foram estimadas separadamente para as culturas da soja e do milho, utilizando-se o estimador de efeitos fixos. Os modelos incorporaram efeitos específicos das unidades do painel, destinados a controlar a heterogeneidade não observada e invariante no tempo, bem como efeitos fixos anuais, para controlar fatores comuns às unidades que variam ao longo do período analisado. Os efeitos individuais controlam características permanentes e não observadas das unidades analisadas, enquanto os efeitos fixos de tempo capturam choques comuns ocorridos em cada ano da amostra, como alterações tecnológicas, institucionais e macroeconômicas.

3.2.1 Modelo baseline

O modelo *baseline* constitui a especificação de referência da pesquisa e tem como finalidade estimar o efeito médio da temperatura e da precipitação sobre a produtividade agrícola.

Formalmente, o modelo pode ser representado por:

$$\ln(y_{it}) = \beta_1 \text{Temp}_{it} + \beta_2 \text{Prec}_{it} + \alpha_i + \gamma_t + \varepsilon_{it} \quad (1)$$

α_i efeitos fixos por estados

γ_t efeito fixos de tempo

Em que (y_{it}) representa o rendimento agrícola da cultura no estado (i) e o período (t); Temp_{it} corresponde à temperatura média observada; Prec_{it} representa a precipitação α_i ; efeitos fixos por estados; γ_t : efeitos fixos de tempo e ε_{it} corresponde ao termo de erro idiossincrático.

A utilização do logaritmo natural do rendimento permite interpretar os coeficientes como elasticidades aproximadas, além de reduzir problemas associados à assimetria da distribuição da variável dependente. Os efeitos fixos estaduais controlam fatores permanentes e não observáveis, como qualidade dos solos, localização geográfica, relevo e características estruturais da produção agrícola. Já os efeitos fixos temporais capturam choques macroeconômicos, mudanças

institucionais e avanços tecnológicos que afetam simultaneamente todas as unidades analisadas.

Embora o modelo *baseline* permita identificar os efeitos médios da temperatura e da precipitação sobre o rendimento agrícola, essa especificação assume que tais impactos ocorrem de forma constante ao longo de toda a distribuição das variáveis climáticas. Entretanto, a literatura recente sugere que a resposta da produtividade agrícola às condições climáticas pode ser não linear, uma vez que temperaturas e níveis de precipitação moderados podem favorecer o desenvolvimento das culturas, enquanto valores extremos tendem a provocar perdas significativas de rendimento.

Nesse contexto, torna-se necessário incorporar termos quadráticos e variáveis de limiar capazes de captar possíveis assimetrias e pontos críticos na relação entre clima e produtividade agrícola.

3.2.2 Modelo de não linearidade climática

Diversos estudos evidenciam que a resposta da produtividade agrícola às condições climáticas pode apresentar comportamento não linear, de modo que os efeitos da temperatura e da precipitação variam conforme os níveis de exposição das culturas a essas condições (Schlenker; Roberts, 2009; Schauburger et al., 2017; Hogan; Schlenker, 2024). Em níveis moderados, temperatura e precipitação podem favorecer o desenvolvimento das culturas; entretanto, valores excessivamente elevados ou reduzidos tendem a provocar perdas de produtividade.

Com o objetivo de captar esse comportamento, foram incorporados termos quadráticos da temperatura e da precipitação, conforme a seguinte especificação:

$$\ln(y_{it}) = \beta_1 \text{Temp}_{it} + \beta_2 \text{Temp}_{it}^2 + \beta_3 \text{Prec}_{it} + \beta_4 \text{Prec}_{it}^2 + \beta_5 \text{Threshold}_{it} + \alpha_i + \gamma_t + \varepsilon_{it} \quad (2)$$

Em que:

Temp_{it}^2 : captura não linearidade

$\text{Threshold}_{it}^1 = \max(\text{Temp}_{it} - 25, 28, 32, 33)$: efeito de temperaturas extremas.

A inclusão de termos quadráticos e variáveis de limiar fundamenta-se na literatura que demonstra que os impactos climáticos não ocorrem de forma

¹ *Threshold*, para fins de robustez foram testados diferentes limiares de 25, 28, 32 e 33 graus °C, mas que nenhum foi significativo.

proporcional. Schlenker e Roberts (2009) verificaram que o rendimento de culturas agrícolas apresenta forte sensibilidade a temperaturas elevadas, com perdas acentuadas quando determinados limiares térmicos são ultrapassados. Da mesma forma, Tanveer e Kalim (2025) demonstram que os efeitos das mudanças climáticas sobre a produtividade agrícola são não lineares e variam de acordo com os níveis de produtividade e condições regionais.

A utilização desse modelo permite identificar possíveis faixas ótimas de temperatura e precipitação, bem como avaliar se os eventos climáticos extremos produzem impactos desproporcionalmente maiores sobre o rendimento agrícola. Para captar possíveis respostas assimétricas e não lineares da produtividade agrícola às condições climáticas, estima-se o seguinte modelo de adaptação:

3.2.3 Modelo de adaptação climática

Além dos efeitos médios e da possível não linearidade, buscou-se investigar se a sensibilidade da produtividade agrícola às variações de temperatura sofreu alterações durante o período analisado.

A literatura sobre adaptação climática sugere que mudanças tecnológicas, melhorias nas práticas de manejo, adoção de cultivares mais resistentes e aperfeiçoamentos na gestão da produção podem contribuir para reduzir a vulnerabilidade da agricultura às condições climáticas adversas e mitigar, ao longo do tempo, parte de seus impactos sobre a produtividade.

Como essas estratégias não são observadas diretamente na base de dados, adotou-se uma medida indireta de adaptação por meio da interação entre temperatura média anual e tendência temporal.

A tendência temporal foi definida como:

$$\ln(y_{it}) = \beta_1 \text{Temp}_{it} + \beta_2 (\text{Temp}_{it} \times \text{Trend}_t) + \beta_3 \text{Prec}_{it} + \alpha_i + \gamma_t + \varepsilon_{it} \quad (3)$$

Em que:

Trend_t : tendência temporal

$\text{Temp}_{it} \times \text{Trend}_t^2$: captura adaptação ao longo do tempo

² Essa variável assume valores sequenciais, iniciando em zero no primeiro ano da amostra e aumentando em uma unidade a cada período subsequente.

A literatura sobre clima e agricultura argumenta que a adaptação pode ocorrer por diferentes mecanismos, incluindo a adoção de cultivares mais resistentes ao calor, alterações no calendário de plantio, expansão da irrigação, melhorias no manejo agrícola e incorporação de novas tecnologias produtivas. Dessa forma, a interação entre temperatura e tendência temporal constitui uma forma indireta de avaliar se esses mecanismos vêm reduzindo os impactos adversos das mudanças climáticas sobre a produtividade agrícola.

Segundo Burke e Emerick (2016), a adaptação agrícola pode ser identificada quando a sensibilidade da produção aos choques climáticos diminui ao longo do tempo, refletindo ajustes tecnológicos e mudanças nas práticas produtivas. De forma semelhante, Ortiz-Bobea *et al.* (2021) destacam que a capacidade adaptativa da agricultura constitui elemento fundamental para mitigar os efeitos negativos das mudanças climáticas sobre a produção mundial de alimentos.

Assim, o modelo de adaptação permite avaliar se a agricultura brasileira tem desenvolvido mecanismos capazes de reduzir os impactos das elevações de temperatura sobre o rendimento das culturas de soja e milho no período analisado.

Quadro 1- Especificações econométricas utilizadas na pesquisa

Modelo	Variáveis incluídas	Objetivo
Baseline	Temperatura média e precipitação	Estimar os efeitos médios das variáveis climáticas sobre a produtividade agrícola.
Não linearidade	Temperatura média, temperatura ² , precipitação e precipitação ²	Avaliar a existência de relações não lineares entre as condições climáticas e a produtividade agrícola, permitindo identificar mudanças no efeito marginal da temperatura e da precipitação.
Adaptação climática	Temperatura média, precipitação e interação temperatura × tendência temporal	Verificar se a sensibilidade da produtividade às variações de temperatura se modificou ao longo do período analisado, fornecendo evidências empíricas compatíveis com adaptação climática.

Fonte: elaboração do autor (2026).

3.6 Base de dados e variáveis

A base de dados utilizada nesta pesquisa foi construída a partir da integração de informações provenientes de instituições oficiais brasileiras, abrangendo o período de 2012 a 2024. A escolha desse recorte temporal possibilitou analisar um período caracterizado por expressiva variabilidade das condições climáticas e do desempenho produtivo da soja e do milho, incluindo anos com diferentes padrões de temperatura,

precipitação e ocorrência de eventos climáticos extremos. Essa variabilidade temporal e espacial fornece condições empíricas relevantes para a estimação dos modelos em painel e para a investigação de possíveis efeitos não lineares e mecanismos de adaptação climática.

As informações referentes à produção agrícola, rendimento por hectare e área plantada foram obtidas no Sistema IBGE de Recuperação Automática (SIDRA), do Instituto Brasileiro de Geografia e Estatística (IBGE, 2025). Essas informações permitem acompanhar a evolução da produção de soja e milho nas unidades da Federação durante todo o período analisado.

Os dados climáticos foram obtidos junto ao Instituto Nacional de Meteorologia (INMET, 2025), contemplando informações de temperatura média anual e precipitação anual. Os registros meteorológicos foram inicialmente coletados em frequência mensal e posteriormente agregados para a frequência anual, tornando-os compatíveis com as informações agrícolas disponibilizadas pelo SIDRA/IBGE.

Para caracterizar a ocorrência de eventos climáticos extremos, utilizaram-se informações provenientes do Programa de Garantia da Atividade Agropecuária (Proagro), vinculado ao Ministério da Agricultura e Pecuária (MAPA, 2025). Esses registros foram empregados na análise descritiva dos principais eventos adversos observados durante o período estudado, como seca, excesso de chuva, geada, granizo e inundação.

Após a integração das bases, os dados foram organizados em estrutura de painel, tendo como unidade de observação a combinação entre unidade da Federação e cultura agrícola ao longo do tempo. Essa estrutura permite acompanhar a evolução das variáveis climáticas e produtivas dentro da mesma unidade de análise durante todo o período da pesquisa.

A base original é composta por 701 observações. Entretanto, para as estimações econométricas foi utilizada apenas a amostra contendo observações com rendimento agrícola estritamente positivo, condição necessária para a aplicação do logaritmo natural na variável dependente. Após esse procedimento, a amostra utilizada nos modelos econométricos passou a ser composta por 618 observações, sendo 350 referentes ao milho e 268 referentes à soja.

As estimações foram realizadas separadamente para cada cultura. Essa opção metodológica fundamenta-se nas diferenças existentes entre soja e milho quanto ao calendário agrícola, exigências fisiológicas, respostas às condições climáticas e

características produtivas, evitando impor coeficientes homogêneos para culturas com comportamentos agronômicos distintos

A Tabela 2 apresenta a definição e a caracterização das variáveis utilizadas nas estimações econométricas, destacando suas unidades de medida, funções nos modelos e respectivas fontes de obtenção dos dados.

3.7 Definição das variáveis

A variável dependente adotada na pesquisa corresponde ao logaritmo natural do rendimento agrícola, originalmente mensurado em quilogramas por hectare (kg/ha). A transformação logarítmica foi empregada apenas para observações com rendimento positivo, permitindo interpretar os coeficientes das variáveis explicativas em termos de variações percentuais aproximadas.

As principais variáveis explicativas são a temperatura média anual, expressa em graus Celsius ($^{\circ}\text{C}$), e a precipitação anual, medida em milímetros (mm). Essas variáveis representam os principais fatores climáticos avaliados pela literatura como determinantes da produtividade agrícola.

Além das variáveis lineares, foram construídas especificações adicionais para avaliar possíveis efeitos não lineares e evidências de adaptação climática. Para a análise da não linearidade, foram incluídos os termos quadráticos da temperatura média e da precipitação. Já para investigar possíveis processos de adaptação ao longo do período analisado, foi construída uma interação entre a temperatura média anual e uma variável de tendência temporal.

A tendência temporal foi definida pela diferença entre o ano da observação e o primeiro ano da amostra, conforme a Equação (1), permitindo avaliar se a sensibilidade da produtividade agrícola à temperatura sofreu alterações ao longo do período analisado.

As variáveis utilizadas nas estimações econométricas são apresentadas na Tabela 2.

Tabela 2- Nomenclatura e especificação das variáveis climáticas (2012-2024).

Variável	Descrição	Unidade de Medida	Tipo	Fonte
In_rend	Logaritmo natural do rendimento agrícola da soja e do milho	ln(kg/ha)	Dependente	SIDRA/IBGE
Temp_Med	Temperatura média anual	°C	Explicativa	INMET
Precipitacao	Precipitação acumulada anual	mm	Explicativa	INMET
Temp ²	Quadrado da temperatura média	°C ²	Não linearidade	Elaboração do autor
Prec ²	Quadrado da precipitação	mm ²	Não linearidade	Elaboração do autor
Threshold	Temperatura 25,28,32 33°C	max(Temp–25,0)	Extremos climáticos	Elaboração do autor
Trend	Tendência temporal (Ano-2012)	Ano	Adaptação	Elaboração do autor
Temp × Trend	Interação entre temperatura e tendência temporal	°C × Ano	Adaptação climática	Elaboração do autor

Fonte: Elaborado pelo autor, 2026

A utilização dessas variáveis permite avaliar não apenas o efeito médio das condições climáticas sobre a produtividade agrícola, mas também investigar possíveis relações não lineares e alterações na resposta das culturas às mudanças climáticas ao longo do tempo.

Diferentemente dos modelos log-log, nos quais tanto a variável dependente quanto as variáveis explicativas são expressas em logaritmo, os modelos estimados nesta pesquisa adotam uma especificação semilogarítmica (log-nível). Nessa especificação, apenas a variável dependente é transformada em logaritmo, enquanto temperatura e precipitação permanecem em suas unidades originais de medida (°C e mm).

Consequentemente, os coeficientes estimados para as variáveis climáticas representam semi-elasticidades, isto é, medem a variação percentual aproximada do rendimento agrícola decorrente de um aumento unitário na variável explicativa, mantendo-se constantes as demais variáveis do modelo. Assim, o coeficiente associado à temperatura indica a variação percentual aproximada da produtividade para um aumento de 1 °C na temperatura média, enquanto o coeficiente da precipitação representa a variação percentual aproximada da produtividade decorrente de um incremento de 1 mm na precipitação média anual.

Para coeficientes de pequena magnitude, essa interpretação pode ser realizada pela aproximação $100 \times \beta$. Quando maior precisão for necessária, a variação percentual exata pode ser obtida por meio da expressão:

$$\% \Delta Y = (\varepsilon^{\beta} - 1) \times 100 \quad (4)$$

Essa interpretação é amplamente adotada na literatura econométrica para modelos semilogarítmicos, nos quais apenas a variável dependente é expressa em logaritmo natural (Gujarati; Porter, 2011; Wooldridge, 2019).

3.8 Seleção do estimador

A definição do estimador mais adequado foi realizada por meio de uma sequência de testes estatísticos tradicionalmente utilizada em modelos de dados em painel. O objetivo desses procedimentos é verificar a existência de heterogeneidade entre as unidades analisadas e identificar a especificação econométrica mais consistente para a estimação dos parâmetros.

Inicialmente, foi aplicado o teste F de Chow para comparar o modelo agrupado (*Pooled OLS*) com o modelo de efeitos fixos. A hipótese nula estabelece que não

existem efeitos individuais entre as unidades do painel, indicando que o modelo agrupado seria suficiente para representar os dados. A rejeição dessa hipótese indica a presença de heterogeneidade não observada entre as unidades, justificando a utilização do modelo de efeitos fixos.

Em seguida, foi empregado o teste do Multiplicador de Lagrange de Breusch-Pagan, que compara o modelo agrupado com o modelo de efeitos aleatórios. A hipótese nula estabelece que a variância do efeito individual é igual a zero, indicando que a estrutura em painel não acrescenta informações em relação ao modelo agrupado. A rejeição da hipótese sugere que a consideração dos efeitos individuais melhora a especificação do modelo.

Posteriormente, realizou-se o teste de Hausman, utilizado para comparar os estimadores de efeitos fixos e efeitos aleatórios. A hipótese nula estabelece que não existe correlação entre os efeitos individuais não observados e as variáveis explicativas, condição necessária para que o estimador de efeitos aleatórios seja consistente. Quando essa hipótese é rejeitada, o estimador de efeitos fixos passa a ser preferível por produzir estimativas consistentes.

Os resultados desses testes fundamentaram a escolha do modelo de efeitos fixos para todas as especificações estimadas nesta pesquisa. Essa escolha é consistente com a existência de características permanentes das unidades analisadas que podem influenciar simultaneamente as condições climáticas e a produtividade agrícola, como fertilidade do solo, relevo, disponibilidade hídrica, infraestrutura produtiva e características tecnológicas regionais.

Dessa forma, todas as estimações foram realizadas utilizando o estimador de efeitos fixos com efeitos fixos anuais, permitindo controlar tanto a heterogeneidade não observada entre as unidades quanto choques comuns ocorridos ao longo do período analisado.

Quadro 2- Procedimentos de seleção do modelo econométrico

Procedimento	Hipótese avaliada	Comparação realizada	Finalidade
Teste F de Chow	Ausência de efeitos individuais	Pooled OLS × Efeitos Fixos	Verificar a necessidade de efeitos específicos por unidade
LM de Breusch-Pagan	Variância do efeito individual igual a zero	Pooled OLS × Efeitos Aleatórios	Avaliar a relevância da estrutura em painel
Teste de Hausman	Ausência de correlação entre efeitos individuais e regressoras	Efeitos Fixos × Efeitos Aleatórios	Definir o estimador consistente

Fonte: Elaboração do autor (2026).

3.9 Testes de diagnóstico

Após a definição do estimador, foram realizados testes para avaliar o atendimento dos principais pressupostos dos modelos de dados em painel e garantir maior confiabilidade às inferências estatísticas.

Inicialmente, foi aplicado o teste de Wooldridge para verificar a presença de autocorrelação serial de primeira ordem nos resíduos. A hipótese nula desse teste estabelece ausência de autocorrelação dentro das unidades do painel. Caso a hipótese seja rejeitada, torna-se necessária a utilização de estimadores robustos para obtenção de erros-padrão consistentes.

Em seguida, utilizou-se o teste de Wald modificado para investigar a presença de heterocedasticidade entre as unidades do painel. A hipótese nula pressupõe variância constante dos resíduos entre os painéis. A rejeição dessa hipótese indica que a variabilidade dos erros difere entre as unidades analisadas, comprometendo a eficiência dos erros-padrão convencionais.

Também foi empregado o teste CD de Pesaran para avaliar a existência de dependência transversal entre as unidades do painel. Esse procedimento verifica se choques não observados afetam simultaneamente diferentes unidades, situação

frequente em estudos climáticos devido à ocorrência de fenômenos meteorológicos de abrangência regional ou nacional.

Além desses procedimentos, foi avaliada a existência de multicolinearidade entre as variáveis explicativas por meio da matriz de correlação e do Fator de Inflação da Variância (*Variance Inflation Factor* – VIF). Nos modelos que incorporam termos quadráticos e interações, parte da correlação entre as regressoras decorre da própria construção matemática das variáveis. Assim, a avaliação da multicolinearidade considerou não apenas os valores individuais do VIF, mas também a estabilidade dos coeficientes estimados e sua coerência econômica.

Para minimizar os efeitos da heterocedasticidade e da autocorrelação serial, todas as estimações foram realizadas utilizando erros-padrão robustos agrupados no nível do painel (*cluster robust standard errors*). Esse procedimento produz estimativas consistentes mesmo quando os resíduos apresentam variância não constante e dependência temporal dentro das unidades analisadas.

Entretanto, os erros-padrão agrupados não corrigem automaticamente problemas de dependência transversal entre os painéis. Por essa razão, os resultados do teste de Pesaran foram considerados na interpretação da robustez das estimativas.

Quadro 3- Testes de diagnóstico econométrico

Teste	Hipótese nula	Objetivo
Wooldridge	Ausência de autocorrelação serial	Verificar dependência temporal dos resíduos
Wald modificado	Homocedasticidade entre os painéis	Identificar heterocedasticidade
Pesaran CD	Independência transversal	Detectar choques comuns entre as unidades
Matriz de correlação e VIF	Ausência de multicolinearidade problemática	Avaliar associação entre regressoras

Fonte: Elaboração do autor (2026).

3.10 Procedimentos de robustez

A robustez dos resultados foi avaliada pela comparação entre as três especificações econométricas estimadas: modelo baseline, modelo de não linearidade climática e modelo de adaptação climática.

A consistência dos resultados foi analisada considerando a estabilidade dos sinais dos coeficientes, a magnitude dos efeitos estimados, a significância estatística

dos parâmetros e a coerência econômica das estimativas entre as diferentes especificações.

Nos modelos de não linearidade, a interpretação dos resultados considerou conjuntamente os termos lineares e quadráticos, bem como a posição dos pontos de inflexão dentro do intervalo observado das variáveis climáticas. Dessa forma, evitou-se interpretar isoladamente a significância estatística dos termos quadráticos.

No modelo de adaptação climática, a análise concentrou-se no comportamento da interação entre temperatura e tendência temporal, verificando se a sensibilidade da produtividade agrícola à temperatura apresentou alterações ao longo do período analisado.

Adicionalmente, a interpretação dos resultados econométricos foi realizada considerando os diagnósticos obtidos pelos testes de autocorrelação, heterocedasticidade, dependência transversal e multicolinearidade, garantindo que as conclusões fossem compatíveis com os pressupostos da estratégia econométrica adotada.

Por fim, os resultados foram discutidos à luz da literatura especializada sobre economia agrícola, mudanças climáticas e produtividade, buscando avaliar a consistência empírica das estimativas obtidas para as culturas da soja e do milho.

3.11 Modelo Econométrico

Nesse contexto, esta pesquisa busca analisar os impactos das variáveis climáticas sobre a produtividade agrícola da soja e do milho no Brasil, considerando explicitamente possíveis efeitos não lineares e mecanismos de adaptação climática entre 2012 e 2024.

Em virtude desta estrutura de dados, onde existem informações para a mesma unidade de análise em dois momentos do tempo, é possível recorrer a abordagem de dados em painel para controlar uma possível heterogeneidade não observada, presente nos dados da amostra e gerar resultados, mas consistentes e eficientes (Wooldridge, 2013). A respeito disso, Hsiao (2003) lista uma série de vantagens advindas da utilização de dados em painel, sendo alguma delas:

- i Controle da heterogeneidade não observada;
- ii Dados em painel são melhores para identificar e mensurar efeitos não observáveis em dados de séries temporais ou em *cross-section*;

iii Dados em painel permitem construir e testar modelos comportamentais mais complexos em relação a modelos de séries temporais ou *cross-section*;

iv Viéses advindos da agregação de dados podem ser reduzidos ou eliminados.

Deste modo, seja qual for a natureza da heterogeneidade presente na amostra, caso ela exista, pode-se recorrer aos modelos *Pooled* ou aos modelos de dados em painel de Efeitos Fixos ou Efeitos Aleatórios, a fim de produzir estimadores consistentes e eficientes que serão capazes de possibilitar que se faça inferências sobre o problema estudado (Greene, 2011). Todavia, a correta especificação sobre qual tipo de modelo utilizar depende da realização de alguns testes, como será abordado na seção 4.

Diante das vantagens e desvantagens supracitadas, o esquema básico para a compreensão dos modelos de painel parte da seguinte regressão, como demonstra Greene (2011) (Equação 5):

$$\begin{aligned} y_{it} &= x_{it}'\beta + z_i'\alpha + \varepsilon_{it} \\ &= x_{it}'\beta + c_i + \varepsilon_{it} \end{aligned} \quad (5)$$

Onde:

y_{it} é variável dependente;

x_{it} é o vetor de variáveis explicativas, onde existem K regressores (não incluído a constante);

$$z_i'\alpha + \varepsilon_{it} \quad (6)$$

ε_{it} é o termo de erro

A partir da Equação 6, pode-se derivar os três tipos de modelos apresentados, isto é, o modelo *Pooled*, o modelo de Efeitos Fixos e o de Efeitos Aleatórios, como serão especificados na seção seguinte.

3.12 Modelo *Pooled* (POLS)

Diante disso, se o termo c_i for observado e invariante para todos os indivíduos da amostra, isto é, se $E[c_i|X_i] = \alpha$, trabalha-se com um modelo *Pooled*. Neste caso, é possível recorrer ao método de Mínimos Quadrados Ordinários (MQO) para estimação do vetor β (Greene, 2011). Assim, Equação 7 pode ser representada como:

$$\begin{aligned}
y_{it} &= \alpha + x_{it}'\beta + \varepsilon_{it} + (c_i - E[c_i|X_i]) \\
&= \alpha + x_{it}'\beta + \varepsilon_{it} + u_i \\
&= \alpha + x_{it}'\beta + w_{it}
\end{aligned} \tag{7}$$

Ou então, em sua forma matricial, onde β passa a incluir a constante:

$$y_i = X_i\beta + w_i \tag{8}$$

Onde w_{it} é o vetor de erros do modelo na ausência de efeito individual.

O modelo de regressão *Pooled* pressupõe, ainda, que o erro tem média zero, variância constante e não é autocorrelacionado; formalmente tem-se:

$$E[\varepsilon_{it}|x_{i1}, x_{i2}, \dots, x_{iT_i}] = 0 \tag{9}$$

$$\text{Var}[\varepsilon_{it}|x_{i1}, x_{i2}, \dots, x_{iT_i}] = \sigma_{\varepsilon^2} \tag{10}$$

$$\text{Cov}[\varepsilon_{it}, \varepsilon_{js}|x_{i1}, x_{i2}, \dots, x_{iT_i}] = 0 \quad \text{se } i \neq j \text{ ou } t \neq s \tag{11}$$

Nestas circunstâncias, com a ausência de um efeito individual, o estimador de β por MQO no modelo *Pooled* (Equação 15) é capaz de produzir estimativas consistentes e eficientes para os parâmetros.

$$\hat{\beta}_{\text{MQO}} = (X'X)^{-1}X'y \tag{12}$$

3.13 Modelo de Efeitos Fixos

Todavia, caso c_i seja não observado, mas correlacionado com x_{it} (Equação 13), o estimador de β por MQO será viesada e inconsistente em virtude da omissão de variável. Neste caso, o modelo abordado é um modelo capaz de controlar Efeitos Fixos (Greene, 2011).

$$E[c_i|X_i] = h(X_i) \neq \alpha \tag{13}$$

Onde $h(X_i)$ representa a heterogeneidade individual, variante entre as unidades da amostra. Como a média condicional de c_i é invariante no tempo, a Equação 9 pode ser escrita da seguinte maneira:

$$\begin{aligned} y_{it} &= x_{it}'\beta + h(X_i) + \varepsilon_{it} + [c_i - h(X_i)] \\ &= x_{it}'\beta + \alpha_i + \varepsilon_{it} + [c_i - h(X_i)] \end{aligned} \quad (14)$$

Dado que $[c_i - h(X_i)]$ é não correlacionado com X_i , este pode ser compreendido pelo termo de erro ε_{it} de modo que o modelo pode ser representado da seguinte forma:

$$y_{it} = x_{it}'\beta + \alpha_i + \varepsilon_{it} \quad (15)$$

Onde α_i é um termo constante no tempo que varia entre os i indivíduos.

Ainda, esta equação pode ser rearranjada para ser representada em sua forma matricial:

$$y_i = X_i\beta + i\alpha_i + \varepsilon_i \quad (16)$$

Onde i é um vetor de números 1.

A partir disto, o estimador para o modelo de dados em painel de Efeitos Fixos pode ser representado por:

$$\hat{\beta}_{EF} = (X'M_D X)^{-1}(X'M_D y) \quad (17)$$

Em que a matriz M_D poder ser representada como:

$$\begin{aligned} M_D &= I - D(D'D)^{-1}D' \\ M_D &= \begin{bmatrix} M_0 & 0 & \cdots & 0 \\ 0 & M_0 & \ddots & 0 \\ 0 & \cdots & \cdots & M_0 \end{bmatrix} \end{aligned} \quad (18)$$

Onde:

$D = [d_1, d_2, \dots, d_n]$;

d_i é a i -ésima variável *dummy*.

Cada matriz na diagonal de M_D é expressa por:

$$M_0 = I_T - \frac{1}{T} ii' \quad (19)$$

Uma vez conhecido o estimador $\hat{\beta}_{EF}$, pode-se retornar à equação normal para isolar o estimador do intercepto $\hat{\alpha}_i$ (Equação 25) que é individual e invariante no tempo.

$$D'D\hat{\alpha} + D'X\hat{\beta} = D'y \quad (20)$$

$$\hat{\alpha} = (D'D)^{-1}D'(y - X\hat{\beta}) \quad (21)$$

$$\hat{\alpha}_i = \bar{y}_i - \bar{x}_i'\hat{\beta} \quad (22)$$

Deste modo, é possível produzir estimadores tanto para a inclinação (Equação 17), quanto para os interceptos (Equação 25) que sejam capazes de controlar os efeitos fixos da amostra e produzir estimativas mais precisas dos parâmetros.

3.14 Modelo de Efeitos Aleatórios

Por sua vez, quando o termo de heterogeneidade individual pode ser considerado não correlacionado com as variáveis do modelo, lida-se com um modelo de Efeitos Aleatórios (Greene, 2011). A Equação 9 neste caso, pode ser expressa da seguinte forma:

$$\begin{aligned} y_{it} &= x_{it}'\beta + E[z_i'\alpha] + \{z_i'\alpha - E[z_i'\alpha] + \varepsilon_{it}\} \\ &= x_{it}'\beta + (\alpha + u_i) + \varepsilon_{it} \end{aligned} \quad (23)$$

Onde: x_{it} é o vetor de variáveis explicativas onde existem K regressores; α é uma constante; u_i é um elemento estocástico específico para cada indivíduo que se mantém em cada período, ao contrário de ε_{it} que varia no tempo t . Assume-se a exogeneidade estrita, assim como formalmente representado:

$$E[\varepsilon_{it}|X] = E[u_i|X] = 0 \quad (24)$$

$$E[\varepsilon_{it}^2|X] = \sigma_\varepsilon^2 \quad (25)$$

$$E[u_i^2|X] = \sigma_u^2 \quad (26)$$

$$E[\varepsilon_{it}\varepsilon_{js}|X] = 0 \quad \text{se } t \neq s \text{ ou } i \neq j \quad (27)$$

$$E[u_i u_j|X] = 0 \quad \text{se } i \neq j \quad (28)$$

Agora, considera-se os termos de erro como:

$$\eta_{it} = \varepsilon_{it} + u_i \quad (29)$$

$$\eta_i = [\eta_{i1}, \eta_{i2}, \dots, \eta_{iT}]' \quad (30)$$

A partir desta estrutura, tem-se um modelo de componentes de erro, que assume os seguintes pressupostos:

$$E[\eta_{it}^2|X] = \sigma_\varepsilon^2 + \sigma_u^2 \quad (31)$$

$$E[\eta_{it}\eta_{is}|X] = \sigma_u^2 \quad \text{se } t \neq s \quad (32)$$

$$E[\eta_{it}\eta_{js}|X] = 0 \quad \text{para todo } t \text{ e } s \text{ se } i \neq j \quad (33)$$

Assim, para as T observações dos i indivíduos, considera-se $\Sigma = E[\eta\eta'i|X]$, deste modo:

$$\Sigma = \begin{bmatrix} \sigma_\varepsilon^2 + \sigma_u^2 & \sigma_u^2 & \dots & \sigma_u^2 \\ \sigma_u^2 & \sigma_\varepsilon^2 + \sigma_u^2 & \dots & \sigma_u^2 \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_u^2 & \sigma_u^2 & \dots & \sigma_\varepsilon^2 + \sigma_u^2 \end{bmatrix} = \sigma_\varepsilon^2 I_T + \sigma_u^2 i_T i_T' \quad (34)$$

$$\Omega = \begin{bmatrix} \Sigma & 0 & \dots & 0 \\ 0 & \Sigma & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \Sigma \end{bmatrix} = I_n \otimes \Sigma \quad (35)$$

Com a finalidade de buscar um estimador para o modelo de efeitos aleatórios, pode se recorrer ao estimador de Mínimos Quadrados Generalizados (MQG) que se utiliza da matriz de ponderação Ω para controlar os efeitos aleatórios. O estimador MQG segue a estrutura apresentada pela Equação 37.

$$\hat{\beta}_{EA} = (X'\Omega^{-1}X)^{-1}X'\Omega^{-1}y \quad (36)$$

$$\Omega^{-1/2} = [I_n \otimes \Sigma]^{-1/2} \quad (37)$$

$$\Sigma^{-1/2} = \frac{1}{\sigma_\varepsilon} \left[I_T - \frac{\theta}{T} i_T i_T' \right] \quad (38)$$

$$\theta = 1 - \frac{\sigma_{\varepsilon}}{\sqrt{\sigma_{\varepsilon}^2 + T\sigma_u^2}} \quad (39)$$

Assim, a transformação de y_i e x_i para MQG se da por:

$$\Sigma^{-1/2}y_i = \frac{1}{\sigma_{\varepsilon}} \begin{bmatrix} y_{i1} - \theta\bar{y}_{i\cdot} \\ \vdots \\ y_{it} - \theta\bar{y}_{i\cdot} \end{bmatrix} \quad (40)$$

Deste modo, confronta-se com três tipos de estimadores. Na ausência de heterogeneidade individual, o estimador de MQO do modelo *Pooled* mostra-se mais apropriado. Entretanto, caso exista efeito individual, e este seja correlacionado com as variáveis explicativas do modelo, pode-se recorrer a estimadores que controlem os Efeitos Fixos. Por último, se o efeito individual estiver correlacionado com o termo de erro, um estimador que controle os Efeitos Aleatórios será capaz de produzir os melhores resultados. A escolha de qual modelo utilizar, por sua vez, depende da realização de uma série de testes, como serão apresentados na seguinte seção.

3.15 Testes de Especificação

Descritas as especificidades que cada modelo pode apresentar, mostra-se necessário realizar uma série de testes, com destaque para o Teste F de Chow, o Teste do Multiplicador de Lagrange (LM) de Breusch–Pagan e o Teste de Hausman, utilizados para subsidiar a escolha entre os estimadores Pooled OLS, efeitos aleatórios e efeitos fixos. para determinação da correta especificação dos modelos estudados. Especificar os modelos de maneira apropriada é fundamental para produzir resultados de qualidade permitindo a correta inferência das informações. Os testes empregados neste trabalho são apresentados subsequentemente.

3.16 Teste F de Chow

Inicialmente, contrapõe-se o modelo *Pooled* com o modelo de Efeitos Fixos através do Teste F de Chow (Gujarati, 2008, Greene, 2011). Aqui, a hipótese nula é representada pela igualdade entre os interceptos para todos os indivíduos, como representa um modelo *Pooled*, isto é:

$$\begin{aligned} \{H_0: \alpha_i &= \alpha \text{ para todo } i \\ H_1: \alpha_i &\neq \alpha \text{ para todo } i \end{aligned}$$

A estatística do teste pode ser representada por:

$$F = \frac{(SQR_r - SQR_{nr})/m}{SQR_{nr}/(n - k)} F(m, n - k) \quad (41)$$

Onde:

SQR_r são a soma dos quadrados dos resíduos do modelo restrito;

SQR_{nr} são a soma dos quadrados dos resíduos do modelo não restrito;

m e $(n - k)$ são os graus de liberdade.

Neste sentido, ao rejeitar a hipótese nula pode-se considerar a existência de heterogeneidade que impossibilita a utilização de um modelo do tipo *Pooled*, assim, a princípio, deve-se optar por um modelo de Efeitos Fixos.

3.17 Teste do Multiplicador de Lagrange

Para testar se um modelo melhor se ajusta com a especificação de Efeitos Aleatórios em relação a um modelo *Pooled*, recorre-se ao Teste do Multiplicador de Lagrange (ML), assim como proposto por Breusch e Pagan (1980). O teste parte da hipótese nula de que os efeitos aleatórios não são significativos e da hipótese alternativa de que os efeitos aleatórios são relevantes e devem ser incluídos no modelo, como segue:

$$\begin{cases} H_0: \sigma_u^2 = 0 \\ H_1: \sigma_u^2 \neq 0 \end{cases}$$

A estatística do teste pode ser representada pela Equação 42:

$$ML = \frac{nT}{2(T - 1)} \left[\frac{\sum_{i=1}^n (T\bar{e}_i)^2}{\sum_{i=1}^n \sum_{t=1}^T e_{it}^2} - 1 \right]^2 \sim \chi_1^2 \quad (42)$$

Onde:

ε é o erro estimado;

T é o número total de unidades de tempo;

n é o número de indivíduos.

Deste modo, ao se rejeitar a hipótese nula parte-se do princípio de que a heterogeneidade da amostra não pode ser descartada, assim, opta-se pela estimação de um modelo de Efeitos Aleatórios em detrimento de um modelo *Pooled* (Greene, 2011).

3.18 Teste de Hausman

Para contrapor um modelo de Efeitos Fixos e um modelo de Efeitos Aleatórios e observar qual é a correta especificação do modelo, aplica-se o Teste de Hausman (1978). O propósito do teste de Hausman é contrastar as estimativas de Efeitos Aleatórios com aquelas de Efeitos Fixos. Quando surgem discrepâncias significativas entre essas estimativas, isso sugere uma possível inconsistência dos estimadores de Efeitos Aleatórios. Deste modo, o teste parte da hipótese nula de que sobre a premissa de não existência de correlação entre ui e X , os estimadores de Efeitos Fixos e de Efeitos Aleatórios são consistentes (Greene, 2011), isto é:

$$\begin{cases} H_0: \hat{\beta}^{EA} = \hat{\beta}^{EF} \\ H_1: \hat{\beta}^{EA} \neq \hat{\beta}^{EF} \end{cases} \quad (43)$$

Sobre essa hipótese, as duas estimativas não devem diferir sistematicamente, assim, pode-se basear um teste em sua diferença. A estatística do teste de Hausman parte da matriz de covariância entre a diferença do vetor $[\hat{\beta}^{EA} - \hat{\beta}^{EF}]$, assim:

$$\text{Var}[\hat{\beta}^{EA} - \hat{\beta}^{EF}] = \text{Var}[\hat{\beta}^{EA}] + \text{Var}[\hat{\beta}^{EF}] - 2\text{Cov}[\hat{\beta}^{EA}, \hat{\beta}^{EF}] \quad (44)$$

Considerando que a covariância entre um estimador eficiente com sua diferença e um estimador eficiente, é zero, tem-se que:

$$\text{Cov}[(\hat{\beta}^{EA} - \hat{\beta}^{EF}), \hat{\beta}^{EA}] = \text{Cov}[\hat{\beta}^{EA}, \hat{\beta}^{EF}] - \text{Var}[\hat{\beta}^{EA}] = 0 \quad (45)$$

Inserindo esse resultado na Equação 44, tem-se que:

$$\text{Cov}[\hat{\beta}^{EA}, \hat{\beta}^{EF}] = \text{Var}[\hat{\beta}^{EA}] \quad (46)$$

$$\text{Var}[\hat{\beta}^{EA} - \hat{\beta}^{EF}] = \text{Var}[\hat{\beta}^{EF}] - \text{Var}[\hat{\beta}^{EA}] \quad (47)$$

A estatística do teste pode ser representada por

$$w = (\hat{\beta}^{EA} - \hat{\beta}^{EF})' [\text{Var}(\hat{\beta}^{EA}) - \text{Var}(\hat{\beta}^{EF})]^{-1} (\hat{\beta}^{EA} - \hat{\beta}^{EF}) \sim \chi_K^2 \quad (48)$$

Assim, ao não rejeitar a hipótese nula assume-se que o modelo de Efeitos Aleatórios é a correta especificação, ao contrário, ao rejeitar a hipótese nula, tem-se que o estimador de Efeitos Fixos fornece a correta especificação. Com isso, somando as contribuições do Teste F de Chow, do Teste do Multiplicador de Lagrange e do Teste de Hausman, é possível especificar o modelo econométrico corretamente e fazer a estimação dos parâmetros a serem estudados (Greene, 2011). Os resultados gerados por essas estimações são apresentados na próxima seção.

Para verificar a adequação dos modelos econométricos estimados, foram realizados testes de especificação e de diagnóstico. Inicialmente, aplicaram-se o Teste F de Chow, o teste do Multiplicador de Lagrange de Breusch-Pagan e o Teste de Hausman, os quais orientam a escolha entre os modelos *Pooled OLS*, Efeitos Fixos e Efeitos Aleatórios. Posteriormente, foram realizados testes para identificar possíveis violações dos pressupostos do modelo, incluindo autocorrelação serial, heterocedasticidade e dependência transversal dos resíduos.

Verificou-se que o teste de Chow e de Hausman foram significativos ($F = 117,16$; $p < 0,001$) e ($\chi^2 = 7,75$; $p < 0,05$). Além disso, observou-se ausência de multicolinearidade expressiva (VIF 1,02) e que os resíduos são potencialmente heterocedásticos ($\chi^2 = 1.342,44$; $p < 0,001$) e autocorrelacionados ($F = 12,102$; $p < 0,001$). Por essa razão, **o modelo de efeitos fixos robusto pode ser considerado o mais adequado**. Adicionalmente, verificou-se que não houve evidências de dependência transversal no painel. Para fins de análise de robustez, foram apresentadas no apêndice as estimações feitas com as especificações *Pooled*, Efeitos Fixos, Aleatórios e Efeitos Fixos Robustos. Destaca-se que todas as estatísticas pertinentes à análise dos modelos também se encontram na tabela 1 do Apêndice. A tabela 1 abaixo reporta os principais resultados para o modelo de efeitos fixos robustos (mais adequado à análise)

3.19 Testes de Robustez

A realização de testes de robustez é fundamental para verificar a consistência e a confiabilidade dos resultados econométricos obtidos. Segundo Wooldridge (2010), a robustez das estimativas permite avaliar se os resultados permanecem estáveis diante de diferentes especificações do modelo e possíveis violações dos pressupostos econométricos.

Inicialmente, a escolha entre os modelos *Pooled* OLS, Efeitos Fixos e Efeitos Aleatórios foi realizada por meio do Teste F de Chow, do Teste do Multiplicador de Lagrange de Breusch e Pagan (1980) e do Teste de Hausman (1978). Esses testes permitem identificar a especificação mais adequada para os dados em painel utilizados na pesquisa.

Posteriormente, foram empregados erros-padrão robustos agrupados por unidade de painel (*cluster*), com o objetivo de corrigir possíveis problemas de heterocedasticidade e autocorrelação serial dentro dos grupos. Conforme Cameron e Trivedi (2009), a utilização de erros-padrão clusterizados produz inferências mais confiáveis em modelos de dados em painel.

Adicionalmente, recomenda-se a realização do teste de autocorrelação serial para dados em painel proposto por Wooldridge (2002), cuja hipótese nula estabelece a ausência de autocorrelação dos resíduos. A presença de autocorrelação pode comprometer a eficiência dos estimadores e produzir erros-padrão inconsistentes.

Também é recomendada a aplicação do teste de heterocedasticidade de Wald Modificado para modelos de efeitos fixos, permitindo verificar se a variância dos resíduos permanece constante entre as unidades de análise. A rejeição da hipótese nula indica a presença de heterocedasticidade, justificando a utilização de estimadores robustos.

Por fim, considerando que os estados brasileiros podem estar sujeitos a choques climáticos comuns, recomenda-se a realização do teste de dependência transversal de Pesaran (2004). Esse procedimento permite verificar se os resíduos apresentam correlação entre as unidades do painel, situação frequentemente observada em estudos climáticos e agrícolas.

A combinação desses procedimentos contribui para aumentar a confiabilidade dos resultados, garantindo que as evidências encontradas sobre os impactos da

temperatura, da precipitação, das não linearidades climáticas e dos mecanismos de adaptação não sejam decorrentes de problemas de especificação econométrica.


4. RESULTADOS E DISCUSSÃO

Este capítulo apresenta os resultados obtidos na análise dos impactos das variáveis climáticas sobre a produtividade da soja e do milho no Brasil, considerando possíveis efeitos não lineares e mecanismos de adaptação climática no período de 2012 a 2024. Inicialmente, são apresentados os resultados das análises exploratórias, com ênfase na evolução da produção, na distribuição regional das culturas e na caracterização das condições climáticas observadas ao longo do período. Em seguida, são discutidos os resultados das estimações econométricas, confrontando-os com as evidências da literatura especializada.

4.1 Análises Exploratória dos Dados

A análise exploratória busca caracterizar a evolução da produção agrícola e das variáveis climáticas utilizadas na pesquisa, fornecendo subsídios para a interpretação dos modelos econométricos apresentados nas seções seguintes. Inicialmente, examina-se a evolução da produção de soja e milho entre 2012 e 2024, apresentada na Figura 2.

Figura 2 Evolução da produção de soja e milho no Brasil (2012-2024).



Fonte: Sidra/IBGE- Elaborada pelo autor, (2026).

A Figura 2 evidencia uma tendência geral de expansão da produção brasileira de soja e milho entre 2012 e 2024, embora as duas culturas apresentem

comportamentos distintos e episódios específicos de redução ao longo da série. Essas oscilações não devem ser atribuídas exclusivamente às condições climáticas, uma vez que fatores como área cultivada, tecnologia, manejo e decisões produtivas também influenciam o volume produzido. Entretanto, em determinados anos, as reduções observadas coincidem com adversidades meteorológicas documentadas por instituições oficiais e pela literatura especializada.

A soja apresentou trajetória predominantemente crescente, passando de aproximadamente 65 milhões de toneladas, em 2012, para cerca de 150 milhões de toneladas em 2023, seguida de redução em 2024. A expansão observada ao longo do período está associada, entre outros fatores, ao aumento da área cultivada, à incorporação de tecnologias agrícolas e à consolidação da cultura no agronegócio brasileiro. Bigolin e Talamini (2024) destacam a relevância do sistema produtivo soja-milho no Brasil e sua exposição às alterações das condições climáticas, especialmente em regiões mais vulneráveis ao aumento da temperatura.

A produção de milho, por sua vez, apresentou maior variabilidade interanual. Em 2016, verificou-se expressiva redução da produção em um contexto marcado por irregularidade das chuvas, estiagem prolongada e temperaturas elevadas, condições que afetaram particularmente o milho de segunda safra (Conab, 2016; IBGE, 2017). Esse período também coincidiu com o forte episódio de *El Niño* de 2015–2016, que provocou alterações relevantes nos padrões de temperatura e precipitação em diferentes regiões produtoras. Assim, embora não seja adequado atribuir toda a redução exclusivamente ao fenômeno climático, as adversidades meteorológicas constituíram importante componente do desempenho produtivo observado naquele ano.

Outro episódio relevante ocorreu em 2021, quando a produção de milho apresentou forte retração. As perdas foram registradas em um contexto de estiagem prolongada e ocorrência de baixas temperaturas e geadas em áreas do Centro-Sul do país, afetando especialmente o milho de segunda safra (Conab, 2021). A soja, em contraste, manteve produção elevada naquele ano, demonstrando que os impactos climáticos podem variar conforme a cultura, o calendário produtivo e o período de exposição aos eventos adversos.

Na safra 2021/22, a soja apresentou redução expressiva da produção. A forte estiagem, a restrição hídrica e as temperaturas elevadas afetaram importantes regiões produtoras, sobretudo a Região Sul e parte de Mato Grosso do Sul. A influência do

fenômeno La Niña sobre a distribuição das precipitações contribuiu para intensificar as condições de déficit hídrico observadas durante etapas relevantes do desenvolvimento da cultura (Conab, 2022). Esse comportamento é consistente com a literatura que identifica a variabilidade climática e a disponibilidade hídrica como importantes condicionantes do desempenho produtivo das culturas de grãos no Brasil (Lisbinski, 2024).

Em 2024, observa-se nova redução na produção de soja e milho em relação aos níveis registrados em 2023. A safra 2023/24 foi marcada por episódios de temperaturas elevadas, irregularidade e escassez de precipitação e estresse hídrico em importantes regiões produtoras. O período também coincidiu com o episódio de *El Niño* de 2023–2024, caracterizado por expressivas anomalias climáticas no território brasileiro, incluindo déficit hídrico em determinadas áreas do Centro-Oeste, da Amazônia e do Pantanal e episódios de precipitação intensa na Região Sul. Esses eventos são compatíveis com as evidências apresentadas por Marengo et al. (2024b) e Toreli et al. (2024) sobre a ocorrência de extremos hidrometeorológicos no período. No caso específico do milho, entretanto, a redução da produção não deve ser explicada apenas pelas condições climáticas, uma vez que a diminuição da área cultivada também contribuiu para o resultado observado (Conab, 2024).


As diferenças entre soja e milho também refletem particularidades dos respectivos sistemas produtivos. Enquanto a soja apresentou trajetória de expansão relativamente mais contínua, o milho demonstrou maior oscilação interanual no período analisado. Essa maior variabilidade é compatível com a exposição do milho, especialmente da segunda safra, às condições de precipitação e temperatura durante fases críticas do ciclo produtivo. Evidências discutidas na literatura indicam que secas, temperaturas elevadas e irregularidades pluviométricas constituem importantes fatores de risco para a produção agrícola, embora seus efeitos variem entre culturas, regiões e sistemas produtivos (Lisbinski, 2024; Wang et al., 2025).

Em síntese, a evolução da produção brasileira de soja e milho entre 2012 e 2024 revela simultaneamente uma trajetória de expansão de longo do período e episódios de retração associados a diferentes fatores produtivos e climáticos. Os anos de 2016, 2021, 2022 e 2024 destacam-se por apresentarem condições meteorológicas adversas concomitantes às reduções observadas em determinadas culturas. Esses resultados reforçam a relevância de investigar econometricamente a relação entre temperatura, precipitação e produtividade agrícola, sem desconsiderar

a influência de fatores tecnológicos, agronômicos e produtivos sobre o desempenho das culturas.

Na Figura 3 apresenta-se a distribuição da produção total de milho entre as regiões brasileiras. A análise permite identificar a participação relativa de cada região na produção nacional, evidenciando a concentração da atividade nas principais áreas produtoras do país e as diferenças regionais associadas às condições climáticas, tecnológicas e produtivas.

Figura 3 Produção de milho por Região (2012-2024).




Fonte: Sidra/IBGE- Elaborada pelo autor, (2026).

A Figura 3 demonstra que a produção de milho está concentrada nas regiões Centro-Oeste e Sul, enquanto Norte e Nordeste apresentam participação significativamente inferior. Esse padrão acompanha a expansão da produção no Cerrado brasileiro, favorecida pela disponibilidade de áreas agricultáveis, elevada mecanização e difusão de tecnologias adaptadas às condições edafoclimáticas da região.

Os resultados corroboram os levantamentos da Conab (2024), que identificam Mato Grosso, Paraná e Goiás como os principais produtores nacionais de milho, bem como estudos da Embrapa (2023), que atribuem a liderança produtiva do Centro-Oeste ao avanço tecnológico e à expansão da fronteira agrícola.

Figura 4 Produção de soja por Região (2012-2024).




Fonte: Sidra/IBGE- Elaborada pelo autor, (2026).

A Figura 4 evidencia concentração da produção de soja nas regiões Centro-Oeste e Sul, com destaque para o Centro-Oeste, responsável pelo maior volume produzido ao longo do período analisado. Esse resultado confirma a importância estratégica dessas regiões para a produção nacional de grãos e reflete a combinação entre condições edafoclimáticas favoráveis, disponibilidade de terras agricultáveis e elevado nível de adoção tecnológica.

Esse padrão está em consonância com os dados da Conab (2024), que apontam Mato Grosso como o principal produtor nacional de soja, e com a Embrapa (2023), segundo a qual a expansão da cultura no Cerrado consolidou o Centro-Oeste como o principal polo produtor do país.

Figura 5 Produção de milho por estados levando em consideração o ZARC- Zoneamento Agrícola de Riscos Climáticos (2012-2024).




Fonte: Sidra/IBGE- Elaborada pelo autor, (2026).

A Figura 5 evidencia elevada concentração da produção de milho em um grupo restrito de estados, destacando-se Mato Grosso, Paraná, Goiás e Mato Grosso do Sul como os principais produtores ao longo do período analisado. Esse padrão confirma a forte especialização produtiva dessas unidades federativas, favorecida pela disponibilidade de áreas agricultáveis, elevada mecanização e ampla adoção de tecnologias adaptadas às condições do Cerrado e da Região Sul.

Os resultados são compatíveis com os levantamentos da Conab (2024), que identificam esses estados como responsáveis por parcela significativa da produção nacional de milho, evidenciando a consolidação do Centro-Oeste como principal fronteira agrícola brasileira.

Figura 6 - Produção de soja por estados levando em consideração o ZARC - Zoneamento Agrícola de Riscos Climáticos (2012-2024).



Fonte: Sidra/IBGE- Elaborada pelo autor, (2026).


A distribuição espacial da produção de soja apresenta padrão semelhante ao observado para o milho. A Figura 6 demonstra forte concentração da produção em Mato Grosso, Paraná, Rio Grande do Sul, Goiás e Mato Grosso do Sul, enquanto os demais estados apresentam participação relativamente reduzida.

Esse comportamento confirma as informações da Conab (2024) e da Embrapa (2023), segundo as quais a expansão da cultura ocorreu principalmente nas áreas do Cerrado, onde a incorporação de inovações tecnológicas, associada às condições edafoclimáticas favoráveis, consolidou o Centro-Oeste como o principal polo produtor de soja do país.

Em conjunto, as Figuras 5 e 6 evidenciam que a produção nacional de soja e milho permanece espacialmente concentrada em estados caracterizados por elevada capacidade tecnológica e grande escala produtiva, aspecto que deve ser considerado na interpretação dos efeitos das variáveis climáticas sobre a produtividade agrícola.

Com o objetivo de caracterizar a variabilidade espacial da precipitação, a Figura 7 apresenta os mapas da precipitação média observada em 2012, 2018 e 2024, além da média do período analisado.

Figura 7 - Distribuição espacial da precipitação média nos estados brasileiros em 2012, 2018, 2024.



Fonte: Instituto Nacional de Meteorologia- INMET. Elaborado pelo autor, (2026)

Na figura referente ao ano de 2012, observa-se elevada concentração de precipitação na Região Norte, especialmente nos estados amazônicos, classificados nas faixas superiores acima de 125 mm e 150 mm. Esse padrão é coerente com a dinâmica climática amazônica, caracterizada por elevada umidade, intensa

evapotranspiração e forte atuação da Zona de Convergência Intertropical (ZCIT). Em contraste, parte significativa do Nordeste apresenta baixos índices pluviométricos, particularmente nas áreas semiáridas, refletindo a irregularidade histórica das chuvas nessa região.

Já na figura de 2018 mantém a estrutura espacial observada anteriormente, porém indica expansão de áreas com precipitação intermediária no Centro-Oeste e Sudeste. Nota-se que o Sul do Brasil apresenta volumes relativamente elevados de precipitação, compatíveis com episódios de chuvas acima da média registrados nesse período. A literatura meteorológica brasileira aponta que 2015–2016 e anos subsequentes foram marcados por anomalias climáticas relevantes associadas ao fenômeno El Niño, alterando o regime hidrológico nacional (Oliveira *et al.* 2022)

Na figura 7, no ano 2024, sugerem persistência da concentração das maiores precipitações na Amazônia e redução relativa das áreas de baixa precipitação no Centro-Sul. Contudo, o Nordeste continua apresentando os menores volumes médios do país, evidenciando permanência da vulnerabilidade hídrica regional. Esse comportamento reforça a ideia de que os efeitos climáticos no Brasil possuem forte componente espacial e regionalizado, afetando de maneira desigual os sistemas produtivos agrícolas.

Ainda na figura 7, o mapa da média do período (*“prec_med”*) sintetiza esse padrão estrutural. A Região Norte permanece como principal núcleo pluviométrico nacional, enquanto o Nordeste semiárido apresenta os menores níveis médios de precipitação. Centro-Oeste, Sudeste e Sul situam-se em níveis intermediários a elevados, embora sujeitos a elevada variabilidade temporal.

Do ponto de vista econômico e agrícola, os mapas evidenciam a importância da disponibilidade hídrica para a produtividade agrícola brasileira, uma vez que a precipitação influencia diretamente o desenvolvimento das culturas ao longo de etapas críticas do ciclo produtivo. Condições adequadas de umidade favorecem o crescimento e o enchimento de grãos, enquanto déficits hídricos podem reduzir o rendimento, especialmente em sistemas de sequeiro, predominantes em grande parte da produção de soja e milho no Brasil.

A literatura demonstra que precipitação adequada tende a elevar a produtividade das culturas, sobretudo em sistemas dependentes de chuva. Entretanto, tanto déficits quanto excessos pluviométricos podem gerar perdas produtivas, caracterizando efeitos não lineares do clima sobre a agricultura. (Assad *et al.* 2024)

Estudos recentes mostram que o aumento da temperatura combinado à redução das chuvas acelera o estresse hídrico, reduzindo a produtividade agrícola e ampliando a vulnerabilidade das regiões tropicais (Assad *et al.*, 2024) e destacam que “havendo redução das chuvas, associada ao aumento de temperatura, as plantas secam mais rápido, promovendo redução da produtividade”. Além disso, pesquisas aplicadas ao Brasil evidenciam que os impactos climáticos tendem a redesenhar gradualmente a geografia agrícola nacional, deslocando áreas mais produtivas para regiões climaticamente mais favoráveis (Tanure *et al.* 2024).


Os padrões espaciais observados nos mapas são consistentes com as evidências apresentadas na literatura acerca da influência da variabilidade climática e dos eventos extremos sobre a agricultura. A distribuição heterogênea da precipitação e a ocorrência de episódios de déficit e excesso hídrico entre as regiões brasileiras evidenciam diferentes níveis de exposição das áreas produtoras aos riscos climáticos, os quais podem afetar o desempenho produtivo da soja e do milho. Estudos identificam aumento da heterogeneidade espacial das precipitações no Brasil, com tendência de secas mais intensas em partes do Norte e Nordeste e aumento de eventos extremos de chuva no Sul do país Lazzari *et al.* (2022). Esse padrão possui implicações diretas para modelos econométricos de produtividade agrícola, especialmente aqueles que incorporam não linearidades, *thresholds* climáticos e mecanismos de adaptação regional.

Nesse sentido, a heterogeneidade espacial observada nos mapas constitui uma evidência descritiva da exposição diferenciada das regiões brasileiras às condições climáticas, fornecendo subsídios para a investigação econométrica subsequente dos efeitos da temperatura e da precipitação sobre a produtividade da soja e do milho. Esse comportamento reforça a pertinência do uso de modelos de efeitos fixos com termos quadráticos, *thresholds* e interações clima × tendência temporal, uma vez que os efeitos climáticos observados não parecem lineares nem homogêneos ao longo do território brasileiro. O mapa 2 mostra a distribuição espacial da temperatura média anual entre os estados da federação.

Considerando a relevância da temperatura para o desenvolvimento das culturas agrícolas, a Figura 8 apresenta a distribuição espacial da temperatura média anual nos estados brasileiros nos anos de 2012, 2018 e 2024. A análise comparativa desses mapas permite identificar padrões regionais de aquecimento e a

heterogeneidade térmica do território brasileiro, fatores que podem influenciar significativamente a produtividade das culturas de soja e milho.

Figura 8 - Distribuição espacial da temperatura média anual nos estados brasileiros em diferentes momentos: 2012, 2018, 2024.



Fonte: Instituto Nacional de Meteorologia- INMET. Elaborado pelo autor, (2026)

Na figura do ano 2012, observa-se uma clara heterogeneidade térmica regional. Os estados da Região Norte aparecem concentrados nas classes mais elevadas de temperatura média, especialmente Amazonas, Pará, Roraima e Amapá, indicando médias superiores a 25 °C e, em vários casos, acima de 27 °C. Em contraste, os estados do Sul do Brasil apresentam temperaturas inferiores a 21 °C, refletindo a influência da latitude, altitude e maior atuação de massas de ar frio.

A figura do ano 2018 revela expansão espacial das faixas mais quentes. Há aumento da intensidade térmica principalmente no Norte e no Centro-Oeste, sugerindo avanço das temperaturas médias elevadas para áreas tradicionalmente

menos quentes. Estados como Mato Grosso, Tocantins e Maranhão passam a integrar classes térmicas superiores. Esse comportamento é compatível com a literatura recente sobre aquecimento regional no Brasil, especialmente em áreas de fronteira agrícola e maior pressão de desmatamento (Reboita *et al.*, 2012, Lanfredi, 2018).

Já na figura referente a 2024, o padrão torna-se ainda mais intenso e homogêneo. Grande parte do território nacional encontra-se nas classes acima de 25°C, e diversos estados atingem a categoria superior (>27°C). O avanço das temperaturas elevadas para o Centro-Sul sugere intensificação do aquecimento climático ao longo do período analisado. O Sul permanece relativamente mais frio, porém com redução das áreas nas menores classes térmicas, indicando perda relativa de amenidade climática.

A figura da média do período (*"temp_med"*) sintetiza esse comportamento estrutural. Nota-se um gradiente térmico bem definido do Sul para o Norte do país. As regiões Norte e Centro-Oeste concentram as maiores temperaturas médias nacionais, enquanto Sul e parte do Sudeste apresentam os menores valores médios. Esse padrão reforça a existência de forte desigualdade espacial dos impactos climáticos no Brasil.


Sob a perspectiva econômica e agrícola, os mapas sugerem que as regiões produtoras do Centro-Oeste e os estados do Maranhão, Tocantins, Piauí e Bahia estão mais expostas ao risco térmico. Temperaturas persistentemente elevadas podem afetar a produtividade agrícola por meio do estresse térmico, aceleração do ciclo fenológico, aumento da evapotranspiração e maior demanda hídrica. Em modelos econométricos de produtividade agrícola, esse comportamento tende a se refletir em coeficientes negativos para temperatura média, especialmente quando os valores ultrapassam limiares fisiológicos das culturas.

A comparação temporal entre 2012 e 2024 sugere intensificação das temperaturas médias em diversas regiões do país, especialmente no Norte, Centro-Oeste e parte do Sudeste. Esse comportamento é compatível com evidências recentes de aquecimento regional observadas no território brasileiro e pode representar um fator de pressão adicional sobre os sistemas agrícolas dependentes das condições climáticas.

Após caracterizar a distribuição espacial da temperatura e da precipitação, esta seção examina a ocorrência dos principais eventos climáticos extremos registrados entre 2012 e 2024 e sua associação com a produtividade agrícola da soja e do milho.

A análise permite identificar a distribuição espacial e temporal desses eventos, bem como sua relevância para a compreensão dos impactos climáticos sobre a produção nacional.

Figura 9- Números de eventos climáticos extremos por estados no Brasil (2012-2024).



Fonte: Programa de Garantia da Atividade Agropecuária (Proagro)- Ministério da Agricultura e Pecuária (MAPA). Elaborada pelo autor, (2026).


A Figura 9 evidencia uma elevada concentração de eventos climáticos extremos nos estados da Região Sul, com destaque para Paraná e Rio Grande do Sul. Também se observam frequências expressivas em São Paulo e Mato Grosso do Sul, indicando maior exposição dessas unidades federativas a secas, chuvas intensas, geadas, granizo e inundações.

Esse padrão é consistente com estudos do INMET³, do CEMADEN⁴ e de Marengo *et al.* (2021). Esse padrão é consistente com os resultados desta pesquisa, que identificaram maior concentração de registros de eventos adversos na Região Sul, especialmente seca, excesso de chuvas e granizo, reforçando a elevada exposição das áreas produtoras de soja e milho à variabilidade hidrometeorológica. Considerando que parte expressiva da produção nacional de soja e milho se concentra nessas regiões, a recorrência desses eventos representa importante fonte de risco para a estabilidade da produção agrícola.

³ Instituto Nacional de Meteorologia

⁴ Centro Nacional de Monitoramento e Alertas de Desastres Naturais – Cemaden/ MCTI

Figura 10 - Eventos de seca por estados (2012-2024).




Fonte: Programa de Garantia da Atividade Agropecuária (Proagro)- Ministério da Agricultura e Pecuária (MAPA). Elaborada pelo autor, (2026).

A Figura 10 demonstra que a seca constituiu o evento climático extremo mais frequente durante o período analisado. Os maiores registros concentram-se no Paraná, Rio Grande do Sul, São Paulo e Mato Grosso do Sul, evidenciando elevada vulnerabilidade hídrica justamente nas principais regiões produtoras de grãos.

Embora esses estados apresentem volumes anuais de precipitação relativamente elevados, a ocorrência recorrente de estiagens indica que o risco agrícola depende não apenas da quantidade total de chuva, mas também de sua distribuição temporal. Assim, períodos prolongados de déficit hídrico durante fases críticas do desenvolvimento das culturas podem comprometer significativamente a produtividade, mesmo em regiões com precipitação média elevada.

A Figura 11 apresenta a distribuição espacial dos estados brasileiros com os maiores índices de ocorrências de chuva em excesso no período compreendido entre janeiro de 2012 e dezembro de 2024.

Figura 11- Eventos de Chuvas em excesso por estados (2012-2024).




Fonte: Programa de Garantia da Atividade Agropecuária (Proagro)- Ministério da Agricultura e Pecuária (MAPA). Elaborada pelo autor, (2026).

A Figura 11 apresenta a distribuição espacial das ocorrências de chuva em excesso entre 2012 e 2024. Os maiores registros concentram-se novamente nos estados do Paraná, Rio Grande do Sul e São Paulo, evidenciando que essas regiões estão simultaneamente expostas a déficits e excessos hídricos.

Esse comportamento confirma que a variabilidade climática constitui importante característica das principais regiões produtoras brasileiras, reforçando que tanto a escassez quanto o excesso de precipitação podem gerar perdas produtivas, dependendo do estágio fenológico das culturas.

Figura 12- Matriz de dispersão, histograma e correlação entre rendimento, temperatura e precipitação (2012-2024).




Fonte: Sidra/IBGE; Programa de Garantia da Atividade Agropecuária (Proagro)- Ministério da Agricultura e Pecuária (MAPA). Elaborada pelo autor, (2026).

Em conjunto, a Figura 12 demonstra que as variáveis climáticas, quando analisadas isoladamente, apresentam baixa correlação linear com o rendimento agrícola. Esse resultado não significa que temperatura e precipitação não influenciem a produtividade, mas apenas que essa influência não é capturada por uma simples correlação bivariada.

Por esse motivo, a utilização de modelos econométricos em dados em painel com efeitos fixos, como os estimados neste estudo, é metodologicamente mais adequada. Esses modelos permitem controlar características específicas dos estados e dos anos, além de incorporar simultaneamente múltiplas variáveis explicativas, fornecendo estimativas mais consistentes dos efeitos da temperatura e da precipitação sobre a produtividade agrícola. Esse tipo de situação é comum em estudos aplicados à economia agrícola, nos quais relações aparentemente fracas na análise descritiva tornam-se estatisticamente significativas após o controle de fatores observáveis e não observáveis.

A Figura 13 apresenta a distribuição da precipitação no Brasil entre 2012 e 2024. O gráfico permite visualizar a variabilidade dos volumes pluviométricos, bem como a ocorrência de valores extremos ao longo do período analisado.

Figura 13- Distribuição média de precipitação no Brasil (2012-2024).




Fonte: Instituto Nacional de Meteorologia- INMET. Elaborado pelo autor, (2026)

A Figura mostra que a precipitação anual no Brasil (2012–2024) apresenta elevada variabilidade. A mediana é de aproximadamente 920 mm, enquanto a média é de cerca de 1.045 mm, indicando assimetria positiva da distribuição. O intervalo

interquartil (aproximadamente 150 a 1.700 mm) evidencia grande dispersão dos dados, e os valores variam de cerca de 100 mm a 3.540 mm. Não foram identificados *outliers*, indicando que todas as observações estão dentro da faixa esperada da distribuição. Esses resultados refletem a heterogeneidade climática do Brasil e justificam a utilização da precipitação como variável explicativa nos modelos econométricos no estudo.

Na figura 14 mostra-se a distribuição da precipitação por região no período analisado de (2012-2024).

Figura 14- Distribuição de Precipitação por Região (2012-2024).



Fonte: Instituto Nacional de Meteorologia- INMET. Elaborado pelo autor, (2026)

Observa-se que a Região Norte apresenta os maiores volumes de precipitação, com mediana em torno de 2.100 mm, além da maior concentração de valores elevados. Apesar disso, a presença de alguns valores atípicos de baixa precipitação indica que, em determinados anos ou localidades, ocorreram acumulados significativamente inferiores ao padrão regional.


As regiões Nordeste, Centro-Oeste, Sudeste e Sul apresentam medianas substancialmente menores, situadas entre aproximadamente 250 mm e 600 mm, evidenciando menores volumes anuais de precipitação em relação ao Norte. Entretanto, os gráficos dessas regiões exibem ampla dispersão, principalmente no

Centro-Oeste e Sul, indicando elevada variabilidade da precipitação ao longo do período analisado.

De forma geral, a figura evidencia a forte heterogeneidade do regime pluviométrico entre as regiões brasileiras. Enquanto a Região Norte mantém elevados índices de precipitação, as demais regiões apresentam menores volumes médios e maior variação entre as observações, refletindo as diferenças climáticas existentes no território nacional.

Na sequência, a Figura 15 apresenta a distribuição da precipitação anual por unidade da Federação no período de 2012 a 2024, permitindo comparar a variabilidade pluviométrica entre os estados brasileiros e identificar diferenças no comportamento da precipitação em cada região do país.

Figura 15- Distribuição de Precipitação por Estados (2012-2024).



Fonte: Instituto Nacional de Meteorologia- INMET. Elaborado pelo autor, (2026)

A Figura 15 evidencia elevada heterogeneidade da precipitação entre os estados brasileiros. Os estados da Região Norte, especialmente Amapá (AP), Amazonas (AM), Acre (AC), Pará (PA), Rondônia (RO) e Roraima (RR), apresentam as maiores medianas de precipitação anual, com valores superiores aos observados nas demais regiões, refletindo o clima predominantemente úmido da Amazônia. Esse comportamento é compatível com os estudos de Marengo *et al.* (2018), que destacam

a influência da Amazônia sobre os regimes pluviométricos nacionais e a maior vulnerabilidade hídrica observada no Nordeste brasileiro.

Na Região Nordeste, predominam menores volumes de precipitação, com medianas reduzidas na maioria dos estados. O Maranhão (MA) constitui uma exceção, apresentando níveis mais elevados de precipitação em comparação aos demais estados nordestinos, em razão da influência de diferentes regimes climáticos em seu território.

Os estados do Centro-Oeste, Sudeste e Sul apresentam medianas intermediárias, porém com ampla dispersão dos dados, indicando elevada variabilidade da precipitação entre os anos analisados. Essa característica é particularmente evidente em estados como Mato Grosso (MT), Paraná (PR), Rio Grande do Sul (RS) e Santa Catarina (SC), que exibem grande amplitude entre os quartis e os valores máximos.

Além disso, observa-se a presença de valores atípicos em alguns estados, principalmente na Região Norte, indicando anos com precipitação excepcionalmente baixa ou elevada em relação ao comportamento habitual. De forma geral, a figura confirma que o regime pluviométrico brasileiro apresenta diferenças marcantes entre as unidades da Federação, refletindo a diversidade climática do país e a elevada variabilidade espacial da precipitação ao longo do período de 2012 a 2024.

Esse padrão é explicado pela atuação da Zona de Convergência Intertropical (ZCIT), pela intensa atividade convectiva tropical e pela reciclagem de umidade promovida pela Floresta Amazônica, que constitui um dos principais centros de geração de vapor d'água da América do Sul (Marengo *et al.*, 2018).

Em contraste, os menores volumes de precipitação são observados nos estados do Semiárido Nordestino, como Bahia, Ceará, Rio Grande do Norte, Paraíba e Pernambuco. Essa característica reflete a elevada vulnerabilidade hídrica da região, cuja precipitação apresenta forte irregularidade temporal e espacial em decorrência das oscilações da ZCIT e das anomalias térmicas dos oceanos Atlântico e Pacífico (Moura; Shukla, 1981).

Considerando a relevância da temperatura como um dos principais determinantes do desempenho agrícola, a Tabela 3 apresenta as estatísticas descritivas da temperatura média dos estados brasileiros entre 2012 e 2024. Os resultados permitem avaliar a distribuição espacial das condições térmicas no país, evidenciando as diferenças climáticas existentes entre as regiões brasileiras.

Tabela 3-Estatísticas descritivas da temperatura média anual por estado brasileiro (2012–2024).

Estados	Observações	Média	Desvio padrão	Mínimo	Máximo
RO	26	27,08	0,3838	26,62	27,92
AC	26	26,53	0,4809	26,06	27,54
AM	26	27,54	0,2564	27,24	28,05
RR	26	27,88	0,6648	27,26	29,89
PA	26	27,19	0,2186	26,92	27,58
AP	26	27,14	0,2631	26,78	27,67
TO	26	27,3	0,2794	26,94	27,83
MA	26	27,72	0,2959	27,16	28,36
PI	26	27,58	0,4074	26,89	28,29
CE	26	27,61	0,2979	26,92	28,04
RN	26	27,80	0,3188	26,99	28,44
PB	26	26,49	0,3097	26,05	27,65
PE	26	26,15	0,5083	25,46	27,6
AL	26	26,23	0,7967	25,61	28,78
SE	26	26,58	0,7769	25,97	29,03
BA	26	25,26	0,5422	24,65	26,69
MG	26	23,45	0,7426	22,8	25,62
ES	26	24,18	0,9090	23,51	26,95
RJ	26	23,34	0,9450	22,56	26,32
SP	26	23,29	0,9974	22,42	26,5
PR	26	21,56	1,2527	20,48	25,57
SC	26	19,13	1,2925	18,01	23,27
RS	26	19,99	1,4392	18,8	24,65
MS	26	25,60	1,0036	24,73	28,74
MT	26	26,74	0,4297	26,3	27,8
GO	26	25,37	0,4793	24,95	26,67
DF	26	23,02	0,5170	22,52	24,41
Total	701	25,47	2.4907	18,01	29,89

Fonte: Instituto Nacional de Meteorologia- INMET. Elaborado pelo autor, (2026)

As estatísticas descritivas revelam significativa heterogeneidade térmica entre os estados brasileiros. As maiores temperaturas médias concentram-se nas regiões Norte e Nordeste, enquanto os menores valores são observados na Região Sul.

Além das diferenças de magnitude, verifica-se menor variabilidade temporal nas regiões amazônicas e maior oscilação térmica nos estados do Sul, resultado compatível com a influência da latitude, da altitude e dos sistemas atmosféricos extratropicais sobre o clima brasileiro.

Sob a perspectiva agrícola, essa heterogeneidade é particularmente relevante, uma vez que temperaturas elevadas podem intensificar o estresse térmico, aumentar a evapotranspiração e reduzir o rendimento das culturas, especialmente quando associadas à limitação hídrica.

A Tabela 4 apresenta as estatísticas descritivas das variáveis de produção agrícola e dos eventos climáticos registrados no Brasil no período de 2012 a 2024, evidenciando a magnitude, a dispersão e a heterogeneidade dos dados utilizados na análise empírica.

Tabela 4-Estatísticas Descritivas: Produção e eventos climáticos no Brasil (2012-2024).

Variáveis	Observações	Média	Desvio padrão	Mínimo	Máximo
Precipitação total anual (mm)	701	1.377	662.21	116	3.539
Temperatura média anual (°C)	701	25,45	2.49	18.01	29.89
Produção de grãos por hectares	701	4.025.058	9.650.754	0	179.000.000
Área plantada por hectare	701	992.345	1.826.541	0	124.400.000
Rendimentos em quilos por hectares	701	3.090	1.925.92	0	9.347

Fonte: Dados do IBGE (SIDRA, INMET), Elaborada pelo autor, (2026)

A Tabela 4 resume as estatísticas descritivas das principais variáveis utilizadas nas estimações econométricas. A precipitação anual apresentou média de 1.377 mm e desvio-padrão de 662,21 mm, variando entre 116 mm e 3.539 mm, evidenciando elevada heterogeneidade espacial dos regimes pluviométricos brasileiros. Em comparação, a temperatura apresentou menor dispersão, com média de 25,45 °C e desvio-padrão de 2,49 °C, característica típica de países de clima predominantemente tropical.

As variáveis produtivas também apresentaram ampla variabilidade. A produção agrícola registrou média aproximada de 4,03 milhões de toneladas, enquanto a área plantada alcançou média de 992 mil hectares e o rendimento agrícola 3.090 kg ha⁻¹. Os elevados desvios-padrão observados refletem diferenças estruturais entre estados, associadas ao porte da produção, às características edafoclimáticas, ao nível tecnológico e às estratégias de manejo adotadas pelos produtores.

De forma geral, as estatísticas descritivas evidenciam elevada heterogeneidade tanto das variáveis climáticas quanto das variáveis produtivas. Essa

variabilidade fornece a dispersão necessária para a estimação de modelos em painel e reforça a possibilidade de existência de relações não lineares entre clima e produtividade, hipótese investigada nas seções econométricas subsequentes.

Tabela 5 apresenta as estatísticas descritivas regionais das variáveis climáticas e produtivas no período de 2012 a 2024, evidenciando as diferenças existentes entre as regiões brasileiras quanto às condições de temperatura, precipitação, produção agrícola, rendimento e área cultivada.

Tabela 5-Análise Descritiva Regional das variáveis climáticas e produtivas no Brasil (2012-2024).

Região	Temperatura Média	Precipitação	Área Plantada	Quantidade Produção	Rendimento (hectare)
Centro Oeste	25,18	1.375,01	3.082.616	1,27e+07	4.600,86
Nordeste	26,83	815,41	325.912,1	940.283.7	1.851,86
Norte	27,24	2.089,41	580.725,7	649.999	3.209,26
Sudeste	23,57	1.192,74	580.725,7	2.542.030	3.309,26
Sul	20,23	1.643,62	2.602.045	1,15e+07	4.615,39
Total	25,47	1.377,00	992.345,4	4.025.058	3.090,53

Fonte: Dados do IBGE (SIDRA, INMET), Elaborada pelo autor, (2026)

A análise regional evidencia diferenças expressivas entre as cinco macrorregiões brasileiras. As regiões Norte e Nordeste apresentam as maiores temperaturas médias, enquanto a Região Sul registra as menores temperaturas e elevados volumes de precipitação. Em contraste, o Centro-Oeste e o Sul concentram os maiores níveis médios de produção e rendimento agrícola, evidenciando a importância dessas regiões para a produção nacional de soja e milho.


Os resultados indicam que o desempenho agrícola não depende exclusivamente das condições climáticas. Apesar das temperaturas relativamente elevadas observadas no Centro-Oeste, essa região apresenta elevados níveis de produtividade, sugerindo que fatores tecnológicos, expansão da agricultura empresarial, mecanização e adoção de cultivares adaptadas desempenham papel importante na mitigação dos efeitos adversos do clima.

Essa evidência reforça um dos pressupostos centrais desta tese: os impactos climáticos sobre a produtividade agrícola são condicionados tanto pelas

características ambientais quanto pela capacidade de adaptação dos sistemas produtivos.

Com o objetivo de avaliar a relação entre disponibilidade hídrica e ocorrência de eventos climáticos extremos, a Figura 16 apresenta a associação entre a precipitação média anual e o número de eventos de seca registrados nos estados brasileiros entre 2012 e 2024, permitindo identificar padrões regionais e possíveis discrepâncias entre volume de chuva e vulnerabilidade à seca.

Figura 16 - Associação entre a precipitação média anual e o número de eventos de seca registrados nos estados brasileiros entre (2012- 2024).




Fonte: Programa de Garantia da Atividade Agropecuária (Proagro) - Ministério da Agricultura e Pecuária (MAPA).Elaborado pelo autor, (2026)

A figura mostra que não há uma relação linear clara entre a precipitação média anual e os registros de seca nos estados brasileiros. Observa-se que estados como Paraná (PR) e São Paulo (SP) concentram os maiores números de registros de seca, enquanto estados com elevada precipitação média, como Amapá (AP) e Amazonas (AM), apresentam poucos registros. A linha de ajuste linear apresenta inclinação pouco acentuada, indicando uma associação linear fraca entre as variáveis. Em conjunto, os resultados sugerem que a ocorrência de seca não depende apenas do

volume médio anual de precipitação, mas também de outros fatores climáticos e regionais que influenciam a distribuição das chuvas ao longo do tempo, conforme discutido por Marengo *et al.* (2022) e Grimm, Barros e Doyle (2000).

Na sequência, a Figura 17 apresenta a relação entre a precipitação anual e o rendimento agrícola para as observações da amostra no período de 2012 a 2024, bem como a linha de ajuste linear estimada.

Figura 17- Relação entre precipitação média anual e eventos de seca nos estados brasileiros (2012-2024).




Fonte: Programa de Garantia da Atividade Agropecuária (Proagro) — Ministério da Agricultura e Pecuária (MAPA). Elaborada pelo autor, (2026).

A Figura 17 mostra uma associação linear positiva, porém fraca, entre a precipitação anual e o rendimento agrícola. Embora a linha de ajuste apresente inclinação positiva, observa-se elevada dispersão dos pontos ao longo de toda a distribuição, indicando que níveis semelhantes de precipitação estão associados a diferentes níveis de rendimento. O coeficiente de correlação de Pearson ($r = 0,134$) e o coeficiente de determinação ($R^2 = 0,018$) confirmam que a precipitação, isoladamente, explica apenas uma pequena parcela da variação do rendimento

agrícola. Esses resultados sugerem que, além da precipitação, outros fatores, como temperatura, características do solo, tecnologia e manejo agrícola, também influenciam o desempenho produtivo das culturas. Esse comportamento é consistente com a literatura, que reconhece a existência de respostas não lineares da produtividade às condições climáticas (Mendelsohn; Nordhaus; Shaw, 1994; Zhang *et al.*, 2022).

Na sequência, a Figura 18 apresenta a evolução anual dos registros de seca no Brasil entre 2012 e 2024, permitindo identificar os períodos de maior ocorrência desse evento climático ao longo da série analisada.

Figura 18 - Evolução dos Eventos de Seca no Brasil (2012-2024).



Fonte: Instituto Nacional de Meteorologia- INMET. Elaborado pelo autor, (2026)

A Figura evidencia que os registros de seca permaneceram reduzidos entre 2012 e 2015, com aumento expressivo a partir de 2016. Observa-se crescimento das ocorrências em 2018, seguido de uma redução em 2019 e novo aumento em 2020, culminando no maior número de registros em 2021. Após esse pico, verifica-se redução em 2022 e 2023, enquanto 2024 apresenta nova elevação das ocorrências, embora inferior ao máximo observado em 2021.

Esse comportamento indica que a ocorrência de eventos de seca tornou-se mais intensa e frequente na segunda metade do período analisado, evidenciando maior variabilidade climática. Esse resultado é consistente com estudos que apontam o aumento da frequência e da intensidade de eventos hidrometeorológicos extremos no Brasil nas últimas décadas, especialmente das secas em diferentes regiões do país

(Marengo *et al.*, 2021; IPCC, 2023). Além disso, Marengo *et al.* (2021) destacam que o aumento da variabilidade climática tem ampliado a ocorrência de secas severas, com impactos diretos sobre a disponibilidade hídrica e a produção agrícola, corroborando o padrão observado na Figura 18

Com o objetivo de avaliar a exposição das principais culturas agrícolas brasileiras aos eventos climáticos extremos, a Tabela 6 apresenta a frequência de ocorrência desses eventos nas culturas da soja e do milho, por região, entre 2012 e 2024. A análise fornece evidências sobre a distribuição espacial dos riscos climáticos e sua potencial influência sobre a produtividade agrícola nacional.

Tabela 6- Distribuição dos eventos climáticos extremos por cultura e região (2012-2024).

Região	Chuva em excesso	Seca	Geada	Granizo	Inundação/Tromba d'água	Variação Excessiva de Temperatura	Ventos Fortes/Frio	Raios
Cultura da Soja								
Norte	187	232	0	1	25	4	0	0
Nordeste	51	819	2	5	18	3	0	0
Sudeste	1.411	8.881	41	728	659	47	42	0
Sul	6.194	76.171	126	4.012	2.138	379	124	29
Centro-Oeste	1.226	11.575	42	262	316	70	44	1
Cultura do Milho								
Norte	5	147	59	0	0	0	0	0
Nordeste	0	97	13	0	0	0	0	0
Sudeste	90	8.538	1.770	79	28	8	158	0
Sul	914	29.651	9.405	1.266	157	230	3.077	16
Centro-Oeste	195	8.613	1.258	112	15	20	218	3
Totais por culturas								
Soja	9.069	97.678	211	5008	3.156	503	210	30
Milho	1.204	47.046	12.505	1457	200	258	3.453	19

Fonte: Programa de Garantia da Atividade Agropecuária (Proagro) - Ministério da Agricultura e Pecuária (MAPA).Elaborado pelo autor, (2026).

Os resultados indicam que a seca foi o principal evento climático registrado para ambas as culturas, com 97.678 ocorrências na soja e 47.046 no milho. Em ambos os casos, a Região Sul concentrou o maior número de registros, totalizando 76.171 ocorrências na soja e 29.651 no milho, corroborando estudos que apontam a elevada recorrência de estiagens nessa região em decorrência da variabilidade climática e da influência do fenômeno El Niño–Oscilação Sul (ENOS) (Marengo *et al.*, 2022; Grimm; Barros; Doyle, 2000).

Na cultura da soja, além da seca, destacaram-se os eventos de excesso de chuvas (9.069 ocorrências) e granizo (5.008 ocorrências), concentrados principalmente na Região Sul. Esse padrão é consistente com a literatura, que identifica essa região como uma das mais suscetíveis à ocorrência de tempestades severas e extremos pluviométricos no Brasil (Reboita *et al.*, 2010).

Para o milho, a geada foi o segundo evento climático mais frequente, com 12.505 ocorrências, das quais 9.405 foram registradas na Região Sul. Esse resultado evidencia a maior exposição da cultura às baixas temperaturas, especialmente durante o período de inverno, caracterizando a geada como um dos principais riscos climáticos para a agricultura da região (Berlato; Farenzena; Fontana, 2005).

De forma geral, a soja apresentou maior ocorrência de eventos relacionados ao excesso de água, como chuvas intensas e inundações, enquanto o milho registrou maior incidência de geadas e ventos fortes. Regionalmente, a Região Sul concentrou a maior parte dos sinistros climáticos para ambas as culturas, seguida pelas regiões Centro-Oeste e Sudeste.

Havendo redução das chuvas, associadas ao aumento de temperatura, as plantas secam mais rápido, promovendo a redução da produtividade. Nobre *et al.* (2014) indicam os possíveis cenários que podem ocorrer no Brasil, para cada região, considerando as alterações de chuva e precipitação pluviométrica. Estudos mostram o impacto da temperatura no desenvolvimento e na produtividade das culturas (Bergamaschi; Matzenauer, 2014; Cruz *et al.*, 2011; Heinemann *et al.*, 2009).

Em síntese, os resultados confirmam que a seca constitui o principal fator de risco climático para a produção de soja e milho no Brasil, resultado consistente com a literatura que identifica o déficit hídrico como um dos principais condicionantes das perdas de produtividade em culturas de grãos (Wang *et al.*, 2024; Lisbinski; Bigolin; Talamini, 2024; Ramirio, 2025).

4.2 Resultados dos modelos econométricos

A seguir, as tabelas 7,8,9,10,11 e 12 apresentam as estimações realizadas através do Modelo de Efeitos Fixos (*Baseline*, Não Linearidade e Adaptação para as culturas soja e milho) tendo como variáveis dependente *In rend* (Rendimentos por quilos/hectares) e as variáveis climáticas (temperatura (°C) e precipitação (mm) no Brasil no período de (2012-2024).

As tabelas 7, 8 e 9 representa os resultados das estimações do milho e as tabelas 10, 11 e 12 trazem os resultados das estimações da soja para os três modelos econométricos.

Tabela 7- Resultados dos modelos de efeito fixos: impactos de temperatura e precipitação sobre a produtividade agrícola do milho (2012-2024).

Variáveis	Coefficiente	Erro-padrão robusto	Estatística t	p-valor
Temperatura média (°C)	-0,0609***	0,0221	-2,76	0,010
Precipitação média (mm)	0,0031***	0,00098	3,21	0,004
2013	0,0375	0,0507	0,74	0,466
2014	0,1193**	0,0487	2,45	0,021
2015	0,1525**	0,0574	2,66	0,013
2016	-0,0743	0,0986	-0,75	0,457
2017	0,2135**	0,0777	2,75	0,011
2018	0,1918**	0,0876	2,19	0,038
2019	0,3403***	0,0863	3,94	0,001
2020	0,3664***	0,0822	4,46	0,000
2021	0,2244**	0,0984	2,28	0,031
2022	0,2326**	0,0926	2,51	0,019
2023	0,4080***	0,0809	5,04	0,000
2024	0,4558***	0,0832	5,48	0,000
Constante	8,9900***	0,5409	16,62	0,000
Observações	350			
R ² (within)	0,3074			
R ² (between)	0,3215			
R ² (overall)	0,2759			
F (14,26)	12,21***			
rho	0,9136			
Prob > F	0,0000			

Notas: Erros-padrão robustos agrupados por painel (26 clusters). Ano-base: 2012. Variável dependente: logaritmo da produtividade agrícola (ln_rend).

*** p < 0,01; ** p < 0,05; * p < 0,10; ns = não significativo.

Fonte: Elaboração própria a partir dos resultados do modelo de efeitos fixos estimado no Stata.

Os resultados do modelo de efeitos fixos indicam que a temperatura média apresentou coeficiente negativo e estatisticamente significativo ($\beta = -0,0609$; $p = 0,010$), evidenciando que o aumento da temperatura reduz a produtividade da cultura do milho. Como o modelo possui especificação semilogarítmica, estima-se que um aumento de 1 °C na temperatura média esteja associado a uma redução aproximada de 6,09% na produtividade, mantendo-se constantes as demais variáveis. Esse resultado sugere que temperaturas mais elevadas intensificam o estresse térmico das

plantas e comprometem o desempenho produtivo da cultura (Assunção; Chein, 2016; Kucharik; Serbin, 2008).

Por outro lado, a precipitação média apresentou coeficiente positivo e estatisticamente significativo ($\beta = 0,0031$; $p = 0,004$), indicando que maiores volumes de precipitação contribuem para o aumento da produtividade do milho. Embora a magnitude do coeficiente seja relativamente pequena, seu sinal positivo evidencia a importância da disponibilidade hídrica para o desenvolvimento da cultura, favorecendo seu crescimento e rendimento Upadhyay *et. al.*, (2024).

Em relação aos efeitos temporais, os anos de 2014, 2015, 2017, 2018, 2019, 2020, 2021, 2022, 2023 e 2024 apresentaram coeficientes positivos e estatisticamente significativos em relação ao ano-base de 2012. Os maiores efeitos foram observados em 2023 e 2024, indicando níveis de produtividade superiores ao longo do período analisado.

A Tabela 8 apresenta os resultados do modelo de não linearidade estimado para a cultura do milho. A inclusão dos termos quadráticos de temperatura e precipitação permite identificar possíveis efeitos não lineares das variáveis climáticas sobre a produtividade agrícola, avaliando se aumentos nessas variáveis geram impactos distintos ao longo de sua distribuição.

Tabela 8 - Modelo de Efeitos Fixos com Não Linearidade Climática do milho (2012-2024).

Variáveis	Coefficiente	Erro-padrão robusto	p-valor
Temperatura média	-0,2965*	0,1649	0,084
Temperatura média ²	0,0056	0,0040	0,176
Precipitação média	0,0136***	0,0038	0,001
Precipitação média ²	-0,0000445***	0,0000152	0,007
Threshold	-0,0063	0,0271	0,818
2013	-0,0012	0,0491	0,980
2014	0,1014*	0,0519	0,061
2015	0,1334*	0,0661	0,054
2016	-0,1236	0,1049	0,249
2017	0,1719**	0,0833	0,049
2018	0,1554*	0,0903	0,097
2019	0,2937***	0,0903	0,003
2020	0,3069***	0,0808	0,001
2021	0,2005**	0,0952	0,045
2022	0,1856*	0,0954	0,063
2023	0,3574***	0,0841	0,000
2024	0,3350***	0,0995	0,002
Constante	10,8631***	1,7005	0,000
Observação	350		
R ² (within)	0,3391		
R ² (between)	0,3940		
R ² (overall)	0,3204		
F(17,26)	13,92		
rho	0,9144		
Prob > F	0,0000		

Notas: Variável dependente: ln_rend. Erros-padrão robustos agrupados por painel. Ano-base: 2012.

*** p<0,01; ** p<0,05; * p<0,10.

Fonte: Elaboração própria a partir dos resultados do modelo de efeitos fixos estimado no Stata.

Os resultados do modelo de não linearidade indicam que a temperatura média apresentou coeficiente negativo e estatisticamente significativo ao nível de 10% ($\beta = -0,2965$; $\rho = 0,084$). Esse resultado demonstra que o aumento da temperatura está associado à redução da produtividade agrícola, mantidas constantes as demais variáveis. Entretanto, como o modelo inclui simultaneamente a temperatura e seu termo quadrático, a magnitude do efeito não deve ser interpretada isoladamente como uma redução fixa de 29,65% para cada aumento de 1 °C. Nesse tipo de especificação,

o efeito marginal da temperatura depende do nível térmico observado e é calculado pela expressão $\beta_1 + \beta_2 T$.

O termo quadrático da temperatura apresentou sinal positivo ($\beta = 0,0056$), mas não foi estatisticamente significativo ($\rho = 0,176$). Portanto, apesar do sinal indicar uma possível curvatura na relação entre temperatura e produtividade, os resultados não fornecem evidências estatísticas suficientes para confirmar a existência de não linearidade térmica na amostra analisada. Da mesma forma, a variável *threshold* apresentou coeficiente negativo ($\beta = -0,0063$), porém não significativo ($\rho = 0,818$). Assim, não se pode afirmar que a produtividade tenha apresentado uma alteração estatisticamente identificável após o limite de temperatura adotado no modelo.

O efeito negativo da temperatura é compatível com a literatura. Schauburger *et al.* (2017) constataram que temperaturas elevadas reduzem a produtividade do milho e da soja, especialmente em sistemas de sequeiro, nos quais o aumento da temperatura intensifica o estresse hídrico. Os autores verificaram reduções relevantes nos rendimentos em dias com temperaturas superiores a 30 °C. Hogan *et al.* (2024) também encontraram relações não lineares entre temperatura e produtividade do milho e da soja, mostrando que temperaturas moderadas podem favorecer o crescimento, enquanto temperaturas muito elevadas reduzem os rendimentos. Em perspectiva mais ampla, Ortiz-Bobea *et al.* (2021) estimaram que as mudanças climáticas antropogênicas reduziram o crescimento da produtividade agrícola global, com impactos mais intensos em regiões quentes, como a América Latina e o Caribe.

Em relação à precipitação, o coeficiente linear apresentou sinal positivo e significância estatística ao nível de 1% ($\beta = 0,0136$; $\rho = 0,001$), enquanto o termo quadrático apresentou sinal negativo e foi estatisticamente significativo ($\beta = -0,0000445$; $\rho = 0,007$). A combinação desses sinais evidencia uma relação côncava entre precipitação e produtividade. Inicialmente, o aumento da precipitação contribui positivamente para a produtividade; contudo, esse benefício diminui à medida que o volume de chuva se eleva. Em níveis elevados, o efeito marginal pode tornar-se negativo.

O ponto de máximo estimado da função quadrática da precipitação é obtido por $-\beta/(2\beta_2)$, correspondendo a aproximadamente 152,8 mm de precipitação. Esse valor somente deve ser interpretado como milímetros caso a variável utilizada no modelo esteja efetivamente expressa em milímetros e corresponda ao mesmo período de agregação informado na base. Acima desse ponto, o modelo estima que

acréscimos de precipitação passam a reduzir a produtividade. Essa estimativa representa um ponto de inflexão econométrico da amostra e não deve ser tratada automaticamente como um limite agrônomo universal.

O resultado da precipitação encontra respaldo em Nguyen, Thompson e Costello (2023), que verificaram que condições moderadamente úmidas podem favorecer a produtividade do milho e da soja, enquanto condições excessivamente úmidas reduzem esses benefícios. O estudo também demonstrou que secas intensas provocam perdas expressivas nas duas culturas. Para o Brasil, Batista, Duku e Hein (2023) constataram que alterações no regime de chuvas associadas ao desmatamento reduziram os rendimentos do sistema soja-milho em estados dos biomas Amazônia e Cerrado, confirmando a importância da regularidade da precipitação para a produção agrícola.

Assim, os resultados desta pesquisa corroboram com a literatura. O coeficiente linear negativo da temperatura está de acordo com estudos que identificam efeitos adversos do aquecimento sobre a produtividade. Entretanto, como o termo quadrático da temperatura e a variável *threshold* não foram significativos, não há evidências suficientes, nesta especificação, para confirmar uma resposta térmica não linear ou um efeito adicional acima do limite adotado. Para a precipitação, os sinais positivos no termo linear e negativo no termo quadrático, ambos significativos, corroboram estudos que mostram que a disponibilidade hídrica beneficia inicialmente as culturas, mas que chuvas excessivas podem comprometer o desempenho produtivo.

Com o objetivo de investigar a capacidade de adaptação da cultura do milho às mudanças nas condições climáticas, a Tabela 9 apresenta os resultados do modelo de adaptação, evidenciando os efeitos das variáveis climáticas e dos mecanismos adaptativos sobre a produtividade agrícola.

Tabela 9- Resultados do Modelo de Efeitos Fixos com Adaptação Climática do milho (2012-2024).

Variáveis	Coeficiente	Erro-padrão Robusto	t	p-valor
Temperatura média	-0,0775***	0,0219	-3,54	0,002
Adaptação	0,0059***	0,0021	2,81	0,009
Precipitação média	0,0028***	0,0009	3,09	0,005
2013	-0,1066	0,0712	-1,50	0,146
2014	-0,1774	0,1083	-1,64	0,113
2015	-0,2972*	0,1617	-1,84	0,078
2016	-0,6710***	0,2297	-2,92	0,007
2017	-0,5303**	0,2438	-2,18	0,039
2018	-0,6971**	0,2937	-2,37	0,025
2019	-0,7123*	0,3475	-2,05	0,051
2020	-0,8281**	0,3934	-2,11	0,045
2021	-1,1122**	0,4498	-2,47	0,020
2022	-1,2374**	0,4974	-2,49	0,020
2023	-1,2584**	0,5684	-2,21	0,036
2024	-1,4395**	0,6472	-2,22	0,035
Constante	9,4446***	0,5280	17,89	0,000
Observação	350			
R ² (within)	0,3415			
R ² (between)	0,3218			
R ² (overall)	0,2446			
F (15,26)	13,43			
rho	0,9206			
Prob > F	0,0000			

Notas: Variável dependente: logaritmo do rendimento agrícola (ln_rend). Erros-padrão robustos agrupados por painel. *** $p < 0,01$; ** $p < 0,05$; * $p < 0,10$.

Fonte: Elaboração própria a partir dos resultados do modelo de efeitos fixos estimado no Stata.

Os resultados do modelo de adaptação climática indicam que a temperatura média apresentou coeficiente negativo e estatisticamente significativo ao nível de 1% ($\beta = -0,0775$; $p = 0,002$), evidenciando que o aumento da temperatura reduz a produtividade agrícola. Considerando a especificação semilogarítmica do modelo, estima-se que um aumento de 1 °C na temperatura média esteja associado a uma redução aproximada de 7,75% na produtividade, mantendo-se constantes as demais variáveis. Esse resultado reforça que temperaturas mais elevadas constituem um importante fator limitante para o desempenho produtivo das culturas analisadas.

A variável adaptação apresentou coeficiente positivo e estatisticamente significativo ao nível de 1% ($\beta = 0,0059$; $p = 0,009$), indicando que o processo de

adaptação ao longo do período analisado contribuiu para reduzir parcialmente os impactos negativos da temperatura sobre a produtividade agrícola. Embora a magnitude do coeficiente seja relativamente pequena, seu sinal positivo sugere a existência de mecanismos de adaptação que atenuam os efeitos adversos das mudanças climáticas, como a incorporação de novas tecnologias, a adoção de cultivares mais resistentes, ajustes no calendário de plantio e melhorias nas práticas de manejo.

A precipitação média apresentou coeficiente positivo e estatisticamente significativo ($\beta = 0,0028$; $p = 0,005$), indicando que maiores volumes de precipitação favorecem o aumento da produtividade agrícola. Apesar da magnitude relativamente reduzida do coeficiente, seu sinal positivo confirma a importância da disponibilidade hídrica para o desenvolvimento das culturas, sobretudo em sistemas produtivos dependentes das condições climáticas.

Os resultados encontrados corroboram a literatura especializada. O efeito negativo da temperatura é consistente com os resultados de Schlenker e Roberts (2009), que demonstraram que temperaturas elevadas reduzem significativamente a produtividade das principais culturas agrícolas. Da mesma forma, Lobell, Schlenker e Costa-Roberts (2011) verificaram que o aumento da temperatura constitui um dos principais fatores responsáveis pela redução da produtividade agrícola em escala global. Para o contexto brasileiro, Bigolin e Talamini (2024) observaram que cenários de mudanças climáticas tendem a reduzir o desempenho produtivo dos sistemas de sucessão soja-milho, especialmente em regiões mais vulneráveis ao aumento da temperatura.

O coeficiente positivo da variável de adaptação também encontra respaldo na literatura. Burke e Emerick (2016) demonstraram que produtores agrícolas desenvolvem mecanismos de adaptação capazes de reduzir parte das perdas provocadas pelas mudanças climáticas, embora esses mecanismos não eliminem completamente os impactos do aquecimento. Resultados semelhantes foram encontrados por Cui (2020), que identificou alterações nos padrões de cultivo como estratégia de adaptação às novas condições climáticas, e por Wimmer *et al.* (2024), que verificaram que mudanças nas decisões de manejo e na organização dos sistemas produtivos contribuem para aumentar a resiliência das propriedades agrícolas diante das tendências climáticas de longo prazo.

Em relação à precipitação, os resultados também são compatíveis com a literatura. Ray *et al.* (2015) demonstraram que a variabilidade climática, especialmente a disponibilidade de água, explica parcela significativa das oscilações da produtividade agrícola em escala global. No Brasil, Silva *et al.* (2021) verificaram que condições adequadas de precipitação favorecem o rendimento da soja, enquanto Nguyen *et al.* (2023) observaram que a disponibilidade hídrica exerce papel fundamental para a produtividade do milho e da soja, reduzindo as perdas associadas aos eventos de seca.

De forma geral, os resultados evidenciam que o aumento da temperatura continua exercendo impacto negativo sobre a produtividade agrícola, enquanto a precipitação contribui positivamente para o desempenho das culturas. Ao mesmo tempo, o coeficiente positivo e significativo da variável de adaptação sugere que os produtores têm incorporado estratégias capazes de mitigar parte dos efeitos adversos das mudanças climáticas, resultado que está em consonância com as evidências empíricas reportadas pela literatura nacional e internacional.

A Tabela 10 apresenta os resultados do modelo *baseline* estimado para a cultura da soja. Essa especificação permite avaliar os efeitos diretos da temperatura e da precipitação sobre a produtividade agrícola, constituindo a referência inicial para a análise dos impactos climáticos sobre o rendimento da cultura.

Tabela 10- Resultados do Modelo de Efeitos Fixos (Baseline) da Soja (2012-2024).

Variável	Coefficiente	Erro-padrão Robusto	t	p-valor	Significância
Temperatura média (temp_med)	-0,0386277	0,0192362	-2,01	0,056	*
Precipitação média (prec_med)	0,0022310	0,0006005	3,72	0,001	***
2013	-0,0388063	0,0547165	-0,71	0,485	ns
2014	-0,0154693	0,0448148	-0,35	0,733	ns
2015	0,0386970	0,0504458	0,77	0,450	ns
2016	-0,0654399	0,0840744	-0,78	0,444	ns
2017	0,1018985	0,0540414	1,89	0,071	*
2018	0,1043770	0,0538656	1,94	0,064	*
2019	0,1334813	0,0450092	2,97	0,007	***
2020	0,1475712	0,0414987	3,56	0,002	***
2021	0,1472041	0,0516792	2,85	0,009	***
2022	0,0426824	0,0384382	1,11	0,277	ns
2023	0,2503152	0,0359497	6,96	0,000	***
2024	0,2257431	0,0543293	4,16	0,000	***
Constante	8,6691270	0,4850064	17,87	0,000	***
Observações	268				
R ² (within)	0,2907				
R ² (between)	0,0795				
R ² (overall)	0,0941				
F(14,25)	11,77				
rho	0,5040				
Prob > F	0,0000				

Notas: Erros-padrão robustos agrupados por painel (26 clusters). Ano-base: 2012. Variável dependente: logaritmo da produtividade agrícola (ln_rend).

*** p < 0,01; ** p < 0,05; * p < 0,10; ns = não significativo.

Fonte: Elaboração própria a partir dos resultados do modelo de efeitos fixos estimado no Stata.

A temperatura média apresentou coeficiente negativo ($\beta = -0,0386$) e significância estatística ao nível de 10% ($p = 0,056$), indicando que elevações na temperatura estão associadas à redução da produtividade agrícola. Considerando a especificação semilogarítmica do modelo, estima-se que um aumento de 1 °C na temperatura média esteja associado a uma redução aproximada de 3,86% na produtividade, mantendo constantes os demais fatores. Embora a significância estatística seja marginal, o sinal do coeficiente está em conformidade com a hipótese de que temperaturas mais elevadas intensificam o estresse térmico das plantas,

aumentam a evapotranspiração e reduzem a eficiência fisiológica das culturas, comprometendo o rendimento agrícola.

A precipitação média apresentou coeficiente positivo ($\beta = 0,002231$) e significância estatística ao nível de 1% ($p = 0,001$), evidenciando que maiores volumes de precipitação favorecem o aumento da produtividade agrícola. Na especificação semilogarítmica, o coeficiente indica que um aumento de uma unidade na variável precipitação está associado a um acréscimo aproximado de 0,22% na produtividade, mantidas constantes as demais variáveis. Esse resultado evidencia a importância da disponibilidade hídrica para o desenvolvimento das culturas, especialmente em sistemas produtivos predominantemente dependentes do regime natural de chuvas.

Os resultados também encontram respaldo em estudos desenvolvidos para o contexto brasileiro. Bigolin e Talamini (2024) verificaram que cenários de mudanças climáticas tendem a reduzir a produtividade do sistema de sucessão soja-milho no Brasil, sobretudo em regiões mais vulneráveis ao aumento da temperatura. Em sentido semelhante, Lisbinski (2024) destaca que a variabilidade climática representa um dos principais determinantes da produção de grãos no país, afetando diretamente o desempenho produtivo do milho, da soja e do trigo.

O efeito positivo da precipitação também é corroborado pela literatura especializada. Ray *et al.* (2015) demonstraram que a variabilidade climática, particularmente a disponibilidade de água, explica parcela significativa das oscilações observadas na produtividade agrícola mundial. No Brasil, Silva *et al.* (2021) verificaram que condições adequadas de precipitação favorecem o rendimento da soja, enquanto Nguyen *et al.* (2023) constataram que eventos prolongados de seca reduziram significativamente a produção de milho e soja no sudeste dos Estados Unidos, evidenciando que a disponibilidade hídrica constitui um dos principais fatores determinantes da produtividade agrícola.

Em conjunto, os resultados do modelo *baseline* indicam que o aumento da temperatura exerce efeito negativo sobre a produtividade agrícola, ao passo que a precipitação contribui positivamente para o desempenho das culturas. Esses achados são coerentes com a literatura nacional e internacional e reforçam que as condições climáticas desempenham papel central na determinação da produtividade agrícola. Ao mesmo tempo, a significância das variáveis climáticas justifica o avanço para especificações econométricas mais abrangentes, capazes de investigar possíveis

efeitos não lineares e mecanismos de adaptação às mudanças climáticas, discutidos nas seções seguintes.

A Tabela 11 apresenta os resultados do modelo de não linearidade para a cultura da soja. A inclusão dos termos não lineares permite verificar a existência de limiares climáticos e possíveis efeitos assimétricos da temperatura e da precipitação sobre a produtividade agrícola.

Tabela 11- Resultados do Modelo de Não Linearidade (Temperatura, Precipitação e Threshold) da soja (2012-2024)

Variável	Coefficiente	Erro-padrão Robusto	t	p-valor
Temperatura média (temp_med)	0,1072	0,2211	0,48	0,632
Temperatura média ²	-0,003470	0,005372	-0,65	0,524
Precipitação média (prec_med)	0,002738	0,001706	1,61	0,121
Precipitação média ²	-0,00000198	0,00000618	-0,32	0,752
Threshold (thresh)	0,033230	0,036471	0,91	0,371
2013	-0,0322	0,0535	-0,60	0,553
2014	-0,0120	0,0451	-0,27	0,791
2015	0,0417	0,0523	0,80	0,433
2016	-0,0625	0,0844	-0,74	0,466
2017	0,0994*	0,0556	1,79	0,086
2018	0,1064*	0,0550	1,93	0,064
2019	0,1363***	0,0458	2,98	0,006
2020	0,1481***	0,0424	3,49	0,002
2021	0,1501***	0,0517	2,91	0,008
2022	0,0428	0,0372	1,15	0,261
2023	0,2538***	0,0383	6,62	0,000
2024	0,2571***	0,0828	3,11	0,005
Constante	7,1403***	2,1745	3,28	0,003
Observações	268			
R ² (within)	0,2929			
R ² (between)	0,0795			
R ² (overall)	0,0941			
F(17,25)	21,06			
rho	0,5040			
Prob > F	0,0000			

Notas: Ano-base = 2012. Erros-padrão robustos agrupados por painel (26 *clusters*).

*** p < 0,01; ** p < 0,05; * p < 0,10.

Fonte: Elaboração própria com base nos resultados do modelo de efeitos fixos estimado no Stata.

O modelo de não linearidade apresentou R² *within* de 0,2929, valor ligeiramente superior ao modelo *baseline* (0,2907), indicando pequeno ganho no poder explicativo.

As variáveis associadas à não linearidade climática não apresentaram significância estatística como temperatura média: p = 0,632; temperatura média²: p = 0,524; precipitação média: p=0,121; precipitação média²: p=0,7525 e *Threshold*: p=0,371

Dessa forma, para esta amostra, não foram encontradas evidências estatísticas de efeitos não lineares da temperatura ou da precipitação sobre a produtividade agrícola, nem de um efeito limiar captado pela variável *threshold*.

Os efeitos anuais mantiveram padrão semelhante ao modelo *baseline*. Os anos de 2019, 2020, 2021, 2023 e 2024 apresentaram coeficientes positivos e estatisticamente significativos, indicando produtividade superior em comparação ao ano-base (2012). Os anos de 2017 e 2018 permaneceram marginalmente significativos ao nível de 10%.

O teste F global do modelo ($F = 21,06$; $p < 0,001$) demonstra que o conjunto das variáveis incluídas é estatisticamente relevante para explicar a produtividade agrícola. Entretanto, individualmente, os termos quadráticos e o *threshold* não apresentaram significância estatística, sugerindo que os dados não fornecem evidências robustas de não linearidade climática nesta especificação.

A Tabela 12 apresenta os resultados do modelo de adaptação estimado para a cultura da soja. A especificação busca identificar evidências de adaptação climática ao longo do tempo, avaliando a capacidade dos sistemas produtivos de reduzir os impactos das variações climáticas sobre o rendimento agrícola.

Tabela 12- Resultados do Modelo de Adaptação Climática da soja (2012-2024).

Variáveis	Coefficiente	Erro-padrão	t	p-valor
Temperatura média (temp_med)	-0,0405**	0,0195	-2,08	0,048
Adaptação (adaptacao)	0,0006	0,0012	0,47	0,645
Precipitação média (prec_med)	0,0022***	0,0006	3,91	0,001
2013	-0,0527	0,0541	-0,97	0,340
2014	-0,0437	0,0593	-0,74	0,468
2015	-0,0041	0,0765	-0,05	0,958
2016	-0,1221	0,1395	-0,88	0,390
2017	0,0311	0,1404	0,22	0,826
2018	0,0199	0,1581	0,13	0,901
2019	0,0334	0,1846	0,18	0,858
2020	0,0338	0,2299	0,15	0,884
2021	0,0199	0,2444	0,08	0,936
2022	-0,0979	0,2943	-0,33	0,742
2023	0,0916	0,3249	0,28	0,780
2024	0,0455	0,3520	0,13	0,898
Constante	8,7189***	0,4824	18,07	0,000
Observações	268			
R ² (within)	0,2917			
R ² (between)	0,0770			
R ² (overall)	0,0968			
F (15,25)	13,88			
rho	0,4982			
Prob >F	0,0000			

Notas: Erros-padrão robustos agrupados por painel. Ano-base = 2012.

*** p < 0,01; ** p < 0,05; * p < 0,10.

Fonte: Elaboração própria com base nos resultados do Stata.

Os resultados do modelo de adaptação climática estimado por meio de efeitos fixos indicam que a produtividade agrícola é significativamente influenciada pelas condições climáticas, especialmente pela temperatura média e pela precipitação. O modelo apresentou significância global ($F = 13,88$; $p < 0,01$), evidenciando que o conjunto das variáveis explicativas contribui para explicar as variações observadas na produtividade agrícola ao longo do período analisado.

A temperatura média apresentou coeficiente negativo e estatisticamente significativo ($\beta = -0,0405$; $p = 0,048$), indicando que elevações na temperatura estão associadas à redução da produtividade agrícola. Considerando que a variável dependente foi especificada em logaritmo, os resultados sugerem que um aumento

de 1°C na temperatura média está associado a uma redução aproximada de 4,05% no rendimento agrícola, mantendo-se constantes os demais fatores. Esse resultado é consistente com a literatura que identifica a elevação da temperatura como um dos principais fatores de risco para a produção agrícola, especialmente em regiões tropicais, onde as culturas frequentemente operam próximas aos seus limites fisiológicos de tolerância térmica.

Por outro lado, a precipitação média apresentou coeficiente positivo e estatisticamente significativo ($\beta = 0,0022$; $p = 0,001$), evidenciando que a disponibilidade hídrica exerce papel fundamental no desempenho produtivo das lavouras. O resultado sugere que aumentos na precipitação contribuem para elevar a produtividade agrícola, corroborando estudos que apontam a água como um dos principais determinantes do crescimento vegetal e da formação da produção agrícola.

A variável de adaptação climática apresentou coeficiente positivo ($\beta = 0,0006$), porém sem significância estatística ($p = 0,645$). Dessa forma, os resultados não fornecem evidências empíricas suficientes para confirmar a existência de ganhos de produtividade associados a processos de adaptação climática no período analisado. Embora o sinal positivo seja compatível com a hipótese de adaptação, a ausência de significância estatística sugere que tais efeitos não podem ser distinguidos de zero com base na amostra utilizada.

As variáveis binárias de tempo referentes aos anos de 2013 a 2024 não apresentaram significância estatística, indicando que, após o controle dos efeitos fixos e das variáveis climáticas, não houve diferenças sistemáticas de produtividade em relação ao ano-base de 2012. Esse resultado sugere que a dinâmica temporal da produtividade foi predominantemente explicada pelas condições climáticas e pelas características específicas dos painéis capturadas pelo modelo.

O coeficiente rho de 0,4982 indica que aproximadamente 49,8% da variabilidade total da produtividade está associada a fatores não observados e invariantes no tempo, específicos de cada painel. Esse resultado reforça a adequação da abordagem de efeitos fixos, uma vez que parcela relevante da heterogeneidade produtiva está relacionada a características estruturais permanentes, como condições edafoclimáticas, aspectos tecnológicos e particularidades regionais não observadas diretamente no modelo.

Em síntese, os resultados evidenciam que temperaturas mais elevadas tendem a reduzir a produtividade agrícola, enquanto maiores níveis de precipitação favorecem

o desempenho produtivo das culturas. Por outro lado, não foram encontradas evidências estatísticas de que os mecanismos de adaptação considerados no modelo tenham sido suficientes para mitigar os efeitos adversos das condições climáticas sobre a produtividade agrícola no período analisado.

5. CONSIDERAÇÕES FINAIS

Esta tese teve como objetivo analisar os impactos das variáveis climáticas sobre a produtividade agrícola da soja e do milho no Brasil, considerando explicitamente possíveis efeitos e evidências de adaptação climática no período de 2012 a 2024. Para tanto, foram utilizados modelos de dados em painel com efeitos fixos, incorporando especificações *baseline*, não lineares e de adaptação climática.

Os resultados evidenciaram que as condições climáticas exercem influência significativa sobre a produtividade agrícola brasileira. De modo geral, aumentos na temperatura estiveram associados à redução do rendimento das culturas, enquanto a precipitação apresentou efeitos positivos sobre a produtividade. Esses resultados corroboram estudos anteriores que identificam a temperatura e a disponibilidade hídrica como importantes determinantes do desempenho agrícola.

As estimações do modelo de não linearidade indicaram que os impactos climáticos não ocorrem de forma proporcional ao longo da distribuição das variáveis climáticas. Os resultados sugerem a existência de respostas assimétricas da produtividade às variações de temperatura e precipitação, reforçando a hipótese de que eventos extremos podem gerar perdas significativamente superiores às previstas por modelos lineares. Esses achados estão alinhados às evidências apresentadas por Schlenker e Roberts (2009) e Gammans, Mérel e Ortiz-Bobea (2017).

No que se refere à adaptação climática, os resultados indicaram evidências de redução parcial da sensibilidade da produtividade agrícola aos efeitos adversos da temperatura ao longo do período analisado. Embora tais evidências não permitam afirmar a existência de adaptação plena, sugerem que avanços tecnológicos, melhorias no manejo agrícola, expansão do uso de cultivares adaptadas e outras estratégias produtivas podem ter contribuído para mitigar parte dos impactos climáticos sobre a agricultura brasileira, em consonância com os argumentos apresentados por Burke e Emerick (2016).

A análise dos eventos climáticos extremos revelou ainda que a seca constituiu o principal fator de risco climático para as culturas analisadas, destacando-se como o evento de maior ocorrência no período estudado. Esse resultado reforça a importância da disponibilidade hídrica para a sustentabilidade da produção agrícola brasileira e evidencia a necessidade de estratégias voltadas à gestão do risco climático.

Em síntese, os resultados demonstram que a agricultura brasileira permanece dependente das condições climáticas, embora existam indícios de adaptação capazes de reduzir parcialmente sua vulnerabilidade. Diante das projeções de intensificação dos eventos climáticos extremos nas próximas décadas, torna-se fundamental ampliar investimentos em pesquisa, inovação tecnológica, melhoramento genético, agricultura de precisão, irrigação eficiente e sistemas de gestão de risco rural.

Por fim, recomenda-se que pesquisas futuras incorporem informações em nível municipal, variáveis relacionadas ao uso de tecnologias agrícolas e indicadores de adaptação mais específicos, permitindo aprofundar a compreensão dos mecanismos por meio dos quais produtores rurais respondem aos desafios impostos pelas mudanças climáticas.

REFERÊNCIAS

AL MAMUN, Abdullah; MOHAMAD, Mohd Rosli; YAACOB, Mohd Rafi Bin; MOHIUDDIN, Muhammad. Intention and behavior towards green consumption among low-income households. *Journal of Environmental Management*, London, v. 227, p. 73–86, 2018. DOI: 10.1016/j.jenvman.2018.08.061.

ALFANI, Federica; ARSLAN, Aslihan; MCCARTHY, Nancy; CAVATASSI, Romina; SITKO, Nicholas J. Climate-change vulnerability in rural Zambia: the impact of an El Niño-induced shock on income and productivity. **ESA Working Papers**, n. 288949. Rome: Food and Agriculture Organization of the United Nations, 2019. DOI: 10.22004/ag.econ.288949.

ARAGÓN, Fernando M.; OTEIZA, Francisco; RUD, Juan Pablo. Climate change and agriculture: farmer adaptation to extreme heat. London: Institute for Fiscal Studies, 2018. (IFS Working Paper W18/06).

ASSAD, Eduardo Delgado; ASSAD, Maria Leonor Ribeiro Casimiro Lopes. Mudanças do clima e agropecuária: impactos, mitigação e adaptação: desafios e oportunidades. *Estudos Avançados*, São Paulo, v. 38, n. 112, p. 271–292, 2024.

AUFFHAMMER, Maximilian; HSIANG, Solomon M.; SCHLENKER, Wolfram; SOBEL, Adam. Using weather data and climate model output in economic analyses of climate change. *Review of Environmental Economics and Policy*, Oxford, v. 7, n. 2, p. 181–198, 2013. DOI: 10.1093/leep/ret016.

BAILEY, R. et al. Extreme weather and resilience of the global food system: synthesis report. London: UK Global **Food Security Programme**, 2015.

BAREILLE, François; CHAKIR, Raja. The impact of climate change on agriculture: a repeat-Ricardian analysis. **Journal of Environmental Economics and Management**, v. 119, art. 102822, 2023. DOI: 10.1016/j.jeem.2023.102822.

BARRIOPEDRO, D.; FISCHER, E. M.; LUTERBACHER, J.; TRIGO, R. M.; GARCÍA-HERRERA, R. The hot summer of 2010: redrawing the temperature record map of Europe. **Science**, v. 332, n. 6026, p. 220-224, 2011. DOI: 10.1126/science.1201224.

BATISTA, Fabiana de Souza; DUKU, Confidence; HEIN, Lars. Deforestation-induced changes in rainfall decrease soybean-maize yields in Brazil. *Ecological Modelling*, v. 486, art. 110533, 2023. DOI: 10.1016/j.ecolmodel.2023.110533.

BERGAMASCHI, Homero; MATZENAUER, Ronaldo. **O milho e o clima**. Porto Alegre: Emater/RS-Ascar, 2014. 84 p. ISBN 978-85-98842-11-0.

BIGOLIN, Tiago; TALAMINI, Edson. Impacts of climate change scenarios on the corn and soybean double-cropping system in Brazil. *Climate*, Basel, v. 12, n. 3, art. 42, 2024. DOI: 10.3390/cli12030042.

BLANC, Élodie; SCHLENKER, Wolfram. The use of panel models in assessments of climate impacts on agriculture. **Review of Environmental Economics and Policy**, v. 11, n. 2, p. 258-279, 2017. DOI: 10.1093/reep/rex016.

BRAIMOH, Ademola; MANYENA, Bernard; OBUYA, Grace; MURAYA, Francis. Assessment of food security early warning systems for East and Southern Africa. **Africa Climate Business Plan Series**, v. 100. Washington, DC: World Bank, 2018.

BREUSCH, Trevor S.; PAGAN, Adrian R. The Lagrange multiplier test and its applications to model specification in econometrics. *The Review of Economic Studies*, Oxford, v. 47, n. 1, p. 239–253, 1980.

BURKE, Marshall; EMERICK, Kyle. Adaptation to climate change: evidence from US agriculture. **American Economic Journal: Economic Policy**, v. 8, n. 3, p. 106-140, 2016. DOI: 10.1257/pol.20130025.

BURKE, Marshall; HSIANG, Solomon M.; MIGUEL, Edward. Global non-linear effect of temperature on economic production. **Nature**, v. 527, p. 235-239, 2015. DOI: 10.1038/nature15725.

CARAUTA, Marcelo; PARUSSIS, Julia; HAMPF, Anna; LIBERA, Affonso; BERGER, Thomas. No more double cropping in Mato Grosso, Brazil? Evaluating the potential impact of climate change on the profitability of farm systems. **Agricultural Systems**, v. 190, art. 103104, 2021. DOI: 10.1016/j.agsy.2021.103104.

CARLETON, Tamma A.; HSIANG, Solomon M. Social and economic impacts of climate. **Science**, v. 353, n. 6304, aad9837, 2016. DOI: 10.1126/science. aad9837.

CARVALHO, André Luiz de; SANTOS, Diogo Victor; MARENGO, José Antônio; COUTINHO, Sonia Maria Viggiani; MAIA, Stoécio Malta Ferreira. Impacts of extreme climate events on Brazilian agricultural production. *Sustainability in Debate*, Brasília, v. 11, n. 3, p. 197–224, 2020. DOI: 10.18472/SustDeb.v11n3.2020.33814.

CHALLINOR, Andrew J.; WATSON, James; LOBELL, David B.; HOWDEN, S. Mark; SMITH, Daniel R.; CHHETRI, Netra. A meta-analysis of crop yield under climate change and adaptation. **Nature Climate Change**, v. 4, p. 287-291, 2014. DOI: 10.1038/nclimate2153.

COBOURN, Kelly; IGNACIUK, Ada. Enabling agriculture's transformative capacity to respond to climate change in the long run. **OECD Food, Agriculture and Fisheries Papers**, n. 215, Paris: OECD Publishing, 2025. DOI: 10.1787/7cef69bc-en.

Communications, v. 11, art. 4991, 2020. DOI: 10.1038/s41467-020-18725-w.

CRIPPA, Monica et al. Food systems are responsible for a third of global anthropogenic GHG emissions. *Nature Food*, London, v. 2, p. 198–209, 2021. DOI: 10.1038/s43016-021-00225-9.

CRIPPA, Monica et al. Food systems are responsible for a third of global anthropogenic greenhouse gas emissions. **Nature Food**, v. 2, n. 3, p. 198-209, 2021. DOI: 10.1038/s43016-021-00225-9.

CRUZ, José Carlos *et al.* **Boas práticas agrícolas: milho**. Sete Lagoas: Embrapa Milho e Sorgo, 2011. 45 p. (Embrapa Milho e Sorgo. **Documentos**, 119). ISSN 1518-4277. Disponível em: <https://www.infoteca.cnptia.embrapa.br/bitstream/doc/908225/1/doc119.pdf>. Acesso em 17/07/2026.

CUI, Xiaomeng. Climate change and adaptation in agriculture: evidence from US cropping patterns. **Journal of Environmental Economics and Management**, v. 101, art. 102306, 2020. DOI: 10.1016/j.jeem.2020.102306.

DELL, Melissa; JONES, Benjamin F.; OLKEN, Benjamin A. Temperature shocks and economic growth: evidence from the last half century. *American Economic Journal: Macroeconomics*, Nashville, v. 4, n. 3, p. 66–95, 2012. DOI: 10.1257/mac.4.3.66.

DELL, Melissa; JONES, Benjamin F.; OLKEN, Benjamin A. What do we learn from the weather? The new climate-economy literature. **Journal of Economic Literature**, v. 52, n. 3, p. 740-798, 2014. DOI: 10.1257/jel.52.3.740.

DESCHÊNES, Olivier; GREENSTONE, Michael. The economic impacts of climate change: evidence from agricultural output and random fluctuations in weather. **American Economic Review**, v. 97, n. 1, p. 354-385, 2007. DOI: 10.1257/aer.97.1.354.

DOYLE, Lisa; NOY, Ilan. The short-run nationwide macroeconomic effects of the Canterbury earthquakes. **New Zealand Economic Papers**, v. 49, n. 2, p. 134-156, 2015. DOI: 10.1080/00779954.2014.885379.

EMEDIEGWU, Lotanna E.; WOSSINK, Ada; HALL, Alistair. The impacts of climate change on agriculture in sub-Saharan Africa: a spatial panel data approach. **World Development**, v. 158, art. 105967, 2022. DOI: 10.1016/j.worlddev.2022.105967.

EVENSON, Robert E.; GOLLIN, Douglas. Assessing the impact of the Green Revolution, 1960 to 2000. *Science*, Washington, v. 300, n. 5620, p. 758–762, 2003. DOI: 10.1126/science.1078710.

FEZZI, Carlo; BATEMAN, Ian J. The impact of climate change on agriculture: nonlinear effects and aggregation bias in Ricardian models of farmland values. *Journal of the Association of Environmental and Resource Economists*, Chicago, v. 2, n. 1, p. 57–92, 2015.

GAMMANS, Matthew; MÉREL, Pierre; ORTIZ-BOBEA, Ariel. Negative impacts of climate change on cereal yields: statistical evidence from France. **Environmental Research Letters**, v. 12, art. 054007, 2017. DOI: 10.1088/1748-9326/aa6b0c.

GREENE, William H. *Econometric analysis*. 7. ed. Upper Saddle River: Prentice Hall, 2011.

GUJARATI, Damodar N.; PORTER, Dawn C. **Basic Econometrics**. 5th ed. New York: McGraw-Hill/Irwin, 2009.

HAGOS, Berhanu Gebre. Climate change driven food inflation in Ethiopia? *Asian Journal of Empirical Research*, v. 8, n. 1, p. 13–22, 2018.

HASEGAWA, Toshihiro; WAKATSUKI, Hitomi; JU, Hui; VYAS, Shalika; NELSON, Gerald C.; FARRELL, Aidan; DERYNG, Delphine; MEZA, Francisco; MAKOWSKI, David. A global dataset for the projected impacts of climate change on four major crops. **Scientific Data**, v. 9, art. 58, 2022. DOI: 10.1038/s41597-022-01150-7.

HASSAN, R. M. Implications of climate change for agricultural sector performance in Africa: Policy **challenges and research agenda**. *Journal of African Economies*, **19(suppl_2)**, ii77-ii105, 2010.

HAUSMAN, Jerry A. Specification tests in econometrics. *Econometrica*, New York, v. 46, n. 6, p. 1251–1271, 1978.

HEINEMANN, A. B.; STONE, L. F.; SILVA, S. C. da. Feijão. In: MONTEIRO, J. E. B. A. (Org.) *Agrometeorologia dos cultivos: o fator meteorológico na produção agrícola*. Brasília: Instituto Nacional de Meteorologia, 2009. p.183-201.

HEINO, Matias et al. Increased probability of hot and dry weather extremes during the growing season threatens global crop yields. **Scientific Reports**, v. 13, art. 3585, 2023. DOI: 10.1038/s41598-023-29378-2.

HOGAN, Dylan; SCHLENKER, Wolfram. Non-linear relationships between daily temperature extremes and US agricultural yields uncovered by global gridded meteorological datasets. **Nature Communications**, v. 15, art. 4638, 2024. DOI: 10.1038/s41467-024-48388-w.

HOWDEN, S. Mark; SOUSSANA, Jean-François; TUBIELLO, Francesco N.; CHHETRI, Netra; DUNLOP, Michael; MEINKE, Holger. Adapting agriculture to climate change. **Proceedings of the National Academy of Sciences**, v. 104, n. 50, p. 19691-19696, 2007. DOI: 10.1073/pnas.0701890104.

HSIANG, Solomon et al. Estimating economic damage from climate change in the United States. **Science**, v. 356, n. 6345, p. 1362-1369, 2017. DOI: 10.1126/science.aal4369.

HSIAO, Cheng. *Analysis of panel data*. 2. ed. Cambridge: Cambridge University Press, 2003.

HU, Tongxi; ZHANG, Xuesong; KHANAL, Sami; WILSON, Robyn; LENG, Guoyong; TOMAN, Elizabeth M.; WANG, Xuhui; LI, Yang; ZHAO, Kaiguang. Climate change impacts on crop yields: a review of empirical findings, statistical crop models, and machine learning methods. **Environmental Modelling & Software**, v. 179, art. 106119, 2024. DOI: 10.1016/j.envsoft.2024.106119.

HULTGREN, Andrew et al. Impacts of climate change on global agriculture accounting for adaptation. **Nature**, v. 642, p. 644-652, 2025. DOI: 10.1038/s41586-025-09085-w.

IIZUMI, T. *et al.* Responses of crop yield growth to global temperature and socioeconomic changes. *Scientific Reports*, v. 7, 7800, 2017. DOI: 10.1038/s41598-017-08214-4.

IPCC. **Climate Change 2022: Impacts, Adaptation and Vulnerability**. Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge: Cambridge University Press, 2022.

IPCC. **Climate Change 2023: Synthesis Report. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change**. Geneva: IPCC, 2023. DOI: 10.59327/IPCC/AR6-9789291691647

JAFINO, Bramka Arga et al. Revised estimates of the impact of climate change on extreme poverty by 2030. Washington: World Bank, 2020. (Policy Research Working Paper, 9417).

KOTZ, Maximilian et al. Global warming and heat extremes to enhance inflationary pressures. **Communications Earth & Environment**, v. 5, art. 116, 2024. DOI: 10.1038/s43247-023-01173-x.

LANFREDI, Isaque Saes. As ondas de calor sobre a América do Sul em suas áreas de atuação regional. 2018. Dissertação (Mestrado em Ciências Atmosféricas) – Instituto de Astronomia, Geofísica e Ciências Atmosféricas, Universidade de São Paulo, São Paulo, 2018.

LAZZARI, Diego; GARCEZ, André; POZZI, Guilherme; POLTOZI, Nicolas; BRITO, Cláudio. Extremos climáticos no Brasil: uma análise paralela das tendências históricas e dos impactos socioeconômicos. *Ciência e Natura*, Santa Maria, v. 47, e13, 2025. DOI: 10.5902/2179460X91373.

LESK, Corey; ANDERSON, Weston; KONAR, Megan. Compound heat and moisture extreme impacts on global crop yields under climate change. **Nature Reviews Earth & Environment**, v. 3, p. 872-889, 2022. DOI: 10.1038/s43017-022-00368-8.

LESK, Corey; ROWHANI, Pedram; RAMANKUTTY, Navin. Influence of extreme weather disasters on global crop production. *Nature*, London, v. 529, p. 84–87, 2016. DOI: 10.1038/nature16467.

LISBINSKI, Fernando Cezar. Variabilidade climática na produção de milho, trigo e soja. *Revista de Política Agrícola*, Brasília, v. 33, 2024.

LIU, Di; MISHRA, Ashok K.; RAY, Deepak K. Sensitivity of global major crop yields to climate variables: a non-parametric elasticity analysis. **Science of The Total Environment**, v. 748, art. 141431, 2020. DOI: 10.1016/j.scitotenv.2020.141431.

LOBELL, David B.; FIELD, Christopher B. Global scale climate-crop yield relationships and the impacts of recent warming. *Environmental Research Letters*, Bristol, v. 2, n. 1, 2007. DOI: 10.1088/1748-9326/2/1/014002.

LOBELL, David B.; SCHLENKER, Wolfram; COSTA-ROBERTS, Justin. Climate trends and global crop production since 1980. **Science**, v. 333, n. 6042, p. 616-620, 2011. DOI: 10.1126/science.1204531.

MARENGO, José A.; CUNHA, Ana Paula Martins; CUARTAS, Luis A.; LEAL, Karina R. D.; BROEDEL, Elton; SELUCHI, Marcelo E.; MICHELLI, Luiz; BAIÃO, Camila F. Extreme drought in the Brazilian Pantanal in 2019–2020: characterization, causes and impacts. *Frontiers in Water*, Lausanne, v. 3, art. 639204, 2021. DOI: 10.3389/frwa.2021.639204.

MARENGO, José A.; CUNHA, Ana Paula Martins; ESPINOZA, Juan Carlos; FU, Rong; SCHÖNGART, Jochen; JIMENEZ, Juan Carlos; COSTA, Marcos H.; RIBEIRO, José M.; WONGCHUIG, Silvio; ZHAO, Shixiong. The drought of Amazonia in 2023–2024. *American Journal of Climate Change*, v. 13, p. 567–597, 2024. DOI: 10.4236/ajcc.2024.134028.

MARENGO, José A.; CUNHA, Ana Paula Martins; NOBRE, Carlos A.; RIBEIRO NETO, Germano G. Extreme drought in Brazil in 2021: impacts and climatic drivers. *Climate Resilience and Sustainability*, Hoboken, v. 1, n. 3, e39, 2022. DOI: 10.1002/cli2.39.

MARENGO, José A.; SOUZA JUNIOR, Carlos M.; THONICKE, Kirsten; BURTON, Christopher; HALLADAY, Kate; BETTS, Richard A.; ALVES, Lincoln M.; SOARES, Wagner R. Changes in climate and land use over the Amazon region: current and future variability and trends. *Frontiers in Earth Science*, Lausanne, v. 6, art. 228, 2018. DOI: 10.3389/feart.2018.00228.

MATOS, Patrícia Francisca; PESSÔA, Vera Lúcia Salazar. A modernização da agricultura no Brasil e os novos usos do território. *Geo UERJ*, Rio de Janeiro, n. 22, p. 290–322, 2012. DOI: 10.12957/geouerj.2012.2456.

MEDEIROS, Francisco Jailson; GOMES, Raimundo Silva; COUTINHO, Maria do Livramento; LIMA, Kenio Costa. Meteorological drought and water resources: historical and future perspective for Rio Grande do Norte State, Northeast Brazil. *International Journal of Climatology*, Hoboken, v. 42, n. 15, p. 8042–8060, 2022. DOI: 10.1002/joc.7624.

MENDELSON, Robert; DINAR, Ariel. Climate change and agriculture: an economic analysis of global impacts. Cheltenham: Edward Elgar, 2009.

MENDELSON, Robert; NORDHAUS, William D.; SHAW, Daigee. The impact of global warming on agriculture: a Ricardian analysis. **American Economic Review**, v. 84, n. 4, p. 753-771, 1994.

MINOLI, Sara; JÄGERMEYR, Jonas; ASSENG, Senthold; URFELS, Anton; MÜLLER, Christoph. Global crop yields can be lifted by timely adaptation of growing

periods to climate change. **Nature Communications**, v. 13, art. 7079, 2022. DOI: 10.1038/s41467-022-34411-5.

MOESSNER, Richhild. Effects of precipitation on food consumer price inflation. **CESifo Working Paper**, n. 9961. Munich: CESifo, 2022.

NEWELL, R. G.; PREST, B. C.; SEXTON, S. E. The GDP-temperature relationship: implications for climate change damages. **Journal of Environmental Economics and Management**, v. 108, art. 102445, 2021. DOI: 10.1016/j.jeem.2021.102445.

NGUYEN, Hai; THOMPSON, Allen; COSTELLO, Christine. Impacts of historical droughts on maize and soybean production in the southeastern United States. *Agricultural Water Management*, v. 281, art. 108237, 2023. DOI: 10.1016/j.agwat.2023.108237.

NOBRE, C. et al. Climate Change Risks Limits to Adaptation. Brazil, v.97, p.5508-21, 2014. DOI: 10.13140/RG.2.2.21924.40329.

OLIVEIRA, F. S.; PRADO, B. R.; MONTEIRO, G. M. J. Impactos das mudanças climáticas na produção agrícola e medidas de adaptação sob percepção de atores e produtores rurais de Nova Friburgo, RJ. Rio de Janeiro: Embrapa Solos, 2022.

ORTIZ-BOBEA, Ariel; AULT, Toby R.; CARRILLO, Carlos M.; CHAMBERS, Robert G.; LOBELL, David B. Anthropogenic climate change has slowed global agricultural productivity growth. *Nature Climate Change*, London, v. 11, n. 4, p. 306–312, 2021. DOI: 10.1038/s41558-021-01000-1.

PAAPE, Marcelo Moreira Pereira. O efeito pluviométrico: uma análise em painel na produtividade agrícola dos municípios brasileiros (2000–2014). 2019. Monografia (Graduação em Economia) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2019.

PENHA, Thiago Augusto Marques; MIYAMOTO, Bruno Chaboli Barros; MAIA, Alexandre Gori. Mudanças climáticas e o impacto na produção agropecuária no Rio Grande do Norte. *Revista Econômica do Nordeste*, Fortaleza, v. 51, n. 2, p. 97–125, 2020.

PIEDRA-BONILLA, E. B. et al. Extreme weather events and crop diversification: climate change adaptation in Brazil. *Mitigation and Adaptation Strategies for Global Change*, v. 30, 28, 2025.

PIRES, Gabrielle F.; ABRAHÃO, Gabriel M.; BRUMATTI, Livia M.; OLIVEIRA, Leydimere J. C.; COSTA, Marcos H.; LIDDICOAT, Spencer; KATO, Etsushi; LADLE, Richard J. Increased climate risk in Brazilian double cropping agriculture systems: implications for land use in Northern Brazil. **Agricultural and Forest Meteorology**, v. 228-229, p. 286-298, 2016. DOI: 10.1016/j.agrformet.2016.07.005.

PRUDENTE JUNIOR, Amauri Cassio et al. Application of the JULES-crop model and agrometeorological indicators for forecasting off-season maize yield in Brazil. **Heliyon**, v. 10, n. 8, e29555, 2024. DOI: 10.1016/j.heliyon.2024.e29555.

QIAO, Cancan; CHENG, Changxiu; ALI, Tariq. How climate change and international trade will shape the future global soybean security pattern. **Journal of Cleaner Production**, v. 422, art. 138603, 2023. DOI: 10.1016/j.jclepro.2023.138603.

RAY, Deepak K.; GERBER, James S.; MACDONALD, Graham K.; WEST, Paul C. Climate variation explains a third of global crop yield variability. **Nature Communications**, v. 6, art. 5989, 2015. DOI: 10.1038/ncomms6989.

REBOITA, M. S. *et al.* Regimes de precipitação na América do Sul: uma revisão bibliográfica. *Revista Brasileira de Meteorologia*, v. 25, n. 2, p. 185–204, 2010.

REZAEI, Ehsan Eyshi *et al.* Climate change impacts on crop yields. **Nature Reviews Earth & Environment**, v. 4, p. 831–846, 2023. DOI: 10.1038/s43017-023-00491-0.

RISING, James; DEVINENI, Naresh. Crop switching reduces agricultural losses from climate change in the United States by half under RCP 8.5. *Nature Communications*, v. 11, art. 4991, 2020. DOI: 10.1038/s41467-020-18725-w.

SCHAUBERGER, Bernhard *et al.* Consistent negative response of US crops to high temperatures in observations and crop models. *Nature Communications*, v. 8, art. 13931, 2017. DOI: 10.1038/ncomms13931.

SCHAUBERGER, Bernhard *et al.* Consistent negative response of US crops to high temperatures in observations and crop models. **Nature Communications**, v. 8, art. 13931, 2017. DOI: 10.1038/ncomms13931.

SCHILLERBERG, T.A.; TIAN, D. Climate impacts on crop productions. In: **ZHANG, Q. (Ed.). Encyclopedia of Smart Agriculture Technologies. Cham: Springer International Publishing, 2022. p.1-12. DOI: https://doi.org/10.1007/978-3-030-89123-7_268-1.**

SCHLENKER, Wolfram; ROBERTS, Michael J. Estimating the impact of climate change on crop yields: the importance of nonlinear temperature effects. Cambridge, MA: National Bureau of Economic Research, 2008. (NBER Working Paper, n. 13799). DOI: 10.3386/w13799.

SCHLENKER, Wolfram; ROBERTS, Michael J. Nonlinear temperature effects indicate severe damages to U.S. crop yields under climate change. *Proceedings of the National Academy of Sciences of the United States of America*, Washington, v. 106, n. 37, p. 15594–15598, 2009. DOI: 10.1073/pnas.0906865106.

SCHLENKER, Wolfram; ROBERTS, Michael J. Nonlinear temperature effects indicate severe damages to U.S. crop yields under climate change. **Proceedings of the National Academy of Sciences**, v. 106, n. 37, p. 15594–15598, 2009. DOI: 10.1073/pnas.0906865106.

SCHMITT, Jonas; OFFERMANN, Frank; SÖDER, Mareike; FRÜHAUF, Cathleen; FINGER, Robert. Extreme weather events cause significant crop yield losses at the farm level in German agriculture. **Food Policy**, v. 112, art. 102359, 2022. DOI: 10.1016/j.foodpol.2022.102359.

SILVA, Evandro H. F. M. da et al. Impact assessment of soybean yield and water productivity in Brazil due to climate change. **European Journal of Agronomy**, v. 129, art. 126329, 2021. DOI: 10.1016/j.eja.2021.126329.

SLOAT, Lindsey L. *et al.* Climate adaptation by crop migration. **Nature Communications**, v. 11, art. 1243, 2020. DOI: 10.1038/s41467-020-15076-4.

SOLAYMANI, Saeed. Impacts of climate change on food security and agriculture sector in Malaysia. *Environment, Development and Sustainability*, Dordrecht, v. 20, n. 4, p. 1575–1596, 2018. DOI: 10.1007/s10668-017-9954-4.

SPERA, Stephanie A.; WINTER, Jonathan M.; PARTRIDGE, Trevor F. Brazilian maize yields negatively affected by climate after land clearing. **Nature Sustainability**, v. 3, p. 845-852, 2020. DOI: 10.1038/s41893-020-0560-3.

TANURE, Tarik Marques do Prado; ANDRADE, Daniel Caixeta; DOMINGUES, Edson. Mudanças climáticas e agricultura familiar: impactos regionais por quartis de produtividade. In: **SEMINÁRIO SOBRE A ECONOMIA MINEIRA**, 19., 2024, Diamantina. Anais. Diamantina: CEDEPLAR/UFMG, 2024.

TANVEER, Zubair; KALIM, Rukhsana. An empirical analysis of climate transition: a global outlook of agriculture productivity. *Journal of Economic Studies*, Bingley, v. 52, n. 6, p. 1025–1042, 2025. DOI 10.1108/JES-07-2024-0466

TCHONKOUANG, Rose Daphnee; ONYEAKA, Helen; NKOUTCHOU, Hugue. Assessing the vulnerability of food supply chains to climate change-induced disruptions. **Science of The Total Environment**, v. 920, art. 171047, 2024. DOI: 10.1016/j.scitotenv.2024.171047.

TORETI, Andrea et al. Drought in the Amazon and the La Plata Basins – December 2024. Luxembourg: Publications Office of the European Union, 2024. (GDO Analytical Report, JRC140741). DOI: 10.2760/9524487.

UNITED NATIONS DEVELOPMENT PROGRAMME (UNDP). Human development report 2021/2022: uncertain times, unsettled lives: shaping our future in a transforming world. New York: United Nations Development Programme, 2022.

UPADHYAY, A.; NIGAM, N.K.; MISHRA, P.K.; RAI, S.C. Climatic variability and its impact on the indigenous agricultural system using panel data analysis in the Sikkim Himalaya, India. **Environmental Monitoring and Assessment**, v.196, n.1 art.33, 2024. DOI:10.1007/s10661-023-12193-7

VARIAN, Hal R. Microeconomia: uma abordagem moderna. 9. ed. Rio de Janeiro: Elsevier, 2015.

VERNER, Dorte et al. Groundswell: preparing for internal climate migration. Washington: World Bank, 2018.

VIEIRA, Andrea Mara; PEREIRA, Camilla Cláudia; TRADDELI, Clelia Mara; PIRES, Márcio Messias; SOUSA, Zelia Dias de; OLIVEIRA, Tayla Évellin de; RAMIRIO,

Lucas Deleon. Impactos das mudanças climáticas na produção agrícola. *Caderno Pedagógico*, Curitiba, v. 22, n. 12, 2025. DOI: 10.54033/cadpedv22n12-224.

WANG, Tianyi; JIANG, Yanan; CHANDIO, Abbas Ali. Climate change, access to credit and grain productivity: evidence from counties in China's major grain-producing provinces. *Frontiers in Sustainable Food Systems*, Lausanne, v. 10, art. 1800174, 2026. DOI: 10.3389/fsufs.2026.1800174.

WANG, Y. et al. Assessing the Influence of Extreme Climate Events on Soybean Yield Losses in Brazil and Argentina from 2001 to 2022. SSRN, 2025. DOI:10.2139/ssrn.5141809. College Park: University of Maryland, 2025.

WANG, Y., FENG, K., SUN, L., XIE, Y., & SONG, X. P. (2024). Satellite-based soybean yield 721 prediction in Argentina: A comparison between panel regression and deep learning methods. 722 *Computers and Electronics in Agriculture*, 221. 723 <https://doi.org/10.1016/j.compag.2024.108978> 724

WHEELER, Tim; VON BRAUN, Joachim. Climate change impacts on global food security. *Science*, v. 341, n. 6145, p. 508–513, 2013. DOI: 10.1126/science.1239402.

WIMMER, Stefan; STETTER, Christian; SCHMITT, Jonas; FINGER, Robert. Farm-level responses to weather trends: a structural model. *American Journal of Agricultural Economics*, Hoboken, v. 106, n. 3, p. 1241–1273, 2024. DOI: 10.1111/ajae.12421.

WING, Ian Sue; DE CIAN, Enrica; MISTRY, Malcolm N. Global vulnerability of crop yields to climate change. **Journal of Environmental Economics and Management**, v. 109, art. 102462, 2021. DOI: 10.1016/j.jeem.2021.102462.

WOOLDRIDGE, J. M. *Introductory Econometrics: A Modern Approach*. 7. ed. Boston: Cengage Learning, 2019.

WOOLDRIDGE, Jeffrey M. **Econometric analysis of cross section and panel data**. 2. ed. Cambridge: MIT Press, 2010.

WOOLDRIDGE, Jeffrey M. *Introductory econometrics: a modern approach*. 5. ed. Mason: South-Western Cengage Learning, 2013.

YAHYAEI, Hamid; KITSIOS, Vassili; DE MELLO, Lurion. Risk transference between climate variability and financial derivatives: implications for global food security. **Journal of Climate Finance**, v. 7, art. 100038, 2024. DOI: 10.1016/j.jclimf.2024.100038.

YU; ZHANG, P.; *et al.* Climate change impacts on crop yield, crop water productivity and food security – A review. *Progress in Natural Science*, v. 19, n. 12, p. 1665–1674, 2009. DOI: 10.1016/j.pnsc.2009.08.001

YUN, Sang-Doo; EVANS, Kevin S.; LEE, Seungki. Spatial panel models of crop yield response to weather: econometric specification strategies and prediction

performance. *Journal of Agricultural and Applied Economics*, Cambridge, v. 54, n. 3, p. 465–490, 2022.

ZAIED, Younes Ben; ZOUABI, Ons. Climate change impacts on agriculture: a panel cointegration approach and application to Tunisia. *Munich Personal RePEc Archive*, Paper n. 64711, 2015.

ZHANG, L., WANG, J., SUN, T., and Wang, X. (2022). Impacts of climate change on the mean and variance of indica and japonica rice yield in China. *Agronomy* 12, n.12, ART.3062,2022. DOI: 10.3390/agronomy12123062

ZHANG, Peng; ZHANG, Junjie; CHEN, Minpeng. Economic impacts of climate change on agriculture: the importance of additional climatic variables other than temperature and precipitation. *Journal of Environmental Economics and Management*, Amsterdam, v. 83, p. 8–31, 2017. DOI: 10.1016/j.jeem.2016.12.001.

ZHAO, C. et al. Temperature increase reduces global yields of major crops in four independent estimates. *Proceedings of the National Academy of Sciences*, v. 114, n. 35, p. 9326–9331, 2017. DOI: 10.1073/pnas.1701762114

ZILLI, Marcia et al. The impact of climate change on Brazil's agriculture. **Science of The Total Environment**, v. 740, art. 139384, 2020. DOI: 10.1016/j.scitotenv.2020.139384.

APÊNDICE(S)

Tabela M1. Estimacões para o Milho – Modelo 1 (*Baseline*)

	(1) Pooled	(2) Efeitos Fixos	(3) Efeitos Aleat3rios	(4) Efeitos Fixos Robustos
temp_med	-0.145*** (-8.59)	-0.0609* (-2.08)	-0.0827** (-3.15)	-0.0609* (-2.76)
prec_med	0.00647*** (5.48)	0.00315*** (3.53)	0.00329*** (3.74)	0.00315** (3.21)
2013.ano		0.0375 (0.56)	0.0330 (0.49)	0.0375 (0.74)
2014.ano		0.119 (1.82)	0.118 (1.79)	0.119* (2.45)
2015.ano		0.153* (2.28)	0.163* (2.43)	0.153* (2.66)
2016.ano		-0.0743 (-1.12)	-0.0688 (-1.03)	-0.0743 (-0.75)
2017.ano		0.214** (3.24)	0.215** (3.23)	0.214* (2.75)
2018.ano		0.192** (2.89)	0.189** (2.83)	0.192* (2.19)
2019.ano		0.340*** (5.10)	0.349*** (5.21)	0.340*** (3.94)
2020.ano		0.366*** (5.53)	0.369*** (5.54)	0.366*** (4.46)
2021.ano		0.224*** (3.39)	0.222*** (3.33)	0.224* (2.28)
2022.ano		0.233*** (3.38)	0.223** (3.23)	0.233* (2.51)
2023.ano		0.408*** (6.05)	0.420*** (6.22)	0.408*** (5.04)
2024.ano		0.456*** (5.19)	0.500*** (5.92)	0.456*** (5.48)
_cons	11.00*** (23.70)	8.990*** (11.92)	9.522*** (13.75)	8.990*** (16.62)
R ²	0.259	0.307	0.293	0.307
VIF M3dio		1.02		
T. de Chow		117.16***		
T. de Hausman		7.75*		
T. de Breush-Pagan		1630.63***		
T. de Homocedasticidade (Wald)		1342.44***		
T. de Autocorrelac3o (Wooldridge)		12.102***		
T. Dep. Transversal (Pesaran)		-0.068 ^{NS}		

Nota: Estatísticas t em par3nteses. * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$.

A Tabela M1 apresenta os resultados para a produtividade do milho considerando quatro especificações: *pooled* OLS, efeitos fixos (EF), efeitos aleatórios (EA) e efeitos fixos com erros-padrão robustos. Em relação à análise, primeiramente é relevante examinar a adequação dos modelos estimados. Neste sentido, destaca-se que o coeficiente de determinação (R^2) variou entre 0,259 e 0,307, o que indica que as variáveis climáticas e os efeitos temporais explicam entre 25,9% e 30,7% da variação observada na produtividade do milho.

O teste de multicolinearidade apresentou um VIF médio de 1,02, valor inferior ao limite convencional de 10. Isso indica ausência de correlação problemática entre as variáveis explicativas.

No que diz respeito à escolha da estrutura de painel, verificou-se que o modelo de efeitos fixos (teste de Chow - 117,16; $p < 0,01$) e de efeitos aleatórios (Breusch-Pagan (1630,63; $p < 0,01$) são mais adequados que o modelo *pooled*. Já o resultado do teste de Hausman (7,75; $p < 0,05$) indicou que o modelo de efeitos aleatórios é inconsistente, ou seja, as evidências apontam que o modelo de efeitos fixos foi o mais adequado.

Não obstante, os testes de Wald (1342,44; $p < 0,01$) e Wooldridge (12,102; $p < 0,01$) indicaram que os resíduos são potencialmente heterocedásticos e autocorrelacionados. Dessa forma, a inferência baseada nos erros-padrão convencionais dos modelos de efeitos fixos pode ser inadequada. Por essa razão, foi estimado o modelo de efeitos fixos robusto, por meio do qual ajusta-se de forma robusta a matriz residual de variâncias e covariâncias. Por fim, foi averiguada a hipótese de independência transversal pelo teste de Pesaran. Os resultados indicaram que os resíduos são independentes (-0.068; $p > 0,1$).

Em relação aos coeficientes, verificou-se que a temperatura média apresentou coeficiente negativo em todas as especificações, o que evidencia um efeito adverso do aumento desse fator climático sobre a produtividade do milho. Por exemplo, no modelo *pooled*, o coeficiente estimado foi de -0,145 ($p < 0,01$), o que indica que um aumento de 1°C na temperatura média está associado a uma redução de aproximadamente 14,5% na produtividade.

Entretanto, esse efeito diminui substancialmente quando a heterogeneidade não observada dos estados é controlada. Para ilustrar, no modelo de efeitos fixos robustos, considerado o mais adequado, o coeficiente foi de -0,0609 ($p < 0,10$). Assim, um aumento de 1°C reduziria a produtividade do milho em aproximadamente 6,1%. A

redução da magnitude entre o modelo *pooled* e de efeitos fixos sugere que parte do efeito inicialmente atribuído à temperatura refletia diferenças estruturais permanentes entre os estados.

A precipitação média apresentou coeficiente positivo e estatisticamente significativo em todas as especificações. No modelo robusto, o coeficiente estimado foi de 0,00315 ($p < 0,05$), o que significa que aumentos na precipitação favorecem a produtividade do milho. Em suma, cada unidade adicional de precipitação eleva a produtividade em aproximadamente 0,315%. Observa-se uma estabilidade do coeficiente entre os modelos de efeitos fixos e efeitos aleatórios, o que demonstra baixa sensibilidade da variável à especificação econométrica.

Em síntese, os resultados indicam que temperaturas mais elevadas reduzem a produtividade do milho, enquanto maiores níveis de precipitação aumentam o rendimento agrícola.

Tabela M2. Estimacões para o Milho – Modelo 2 (No linearidade)

	(1) Pooled	(2) Efeitos Fixos	(3) Efeitos Aleatrios	(4) Efeitos Fixos Robustos
temp_med	1.247*** (3.57)	-0.297 (-1.12)	-0.100 (-0.38)	-0.297 (-1.80)
c.temp_med#c.t emp_med	-0.0304*** (-3.93)	0.00556 (0.93)	0.000226 (0.04)	0.00556 (1.39)
prec_med	0.0599*** (11.53)	0.0136*** (4.70)	0.0149*** (5.04)	0.0136** (3.56)
c.prec_med#c.p rec_med	-0.000236*** (-10.04)	-0.0000445*** (-3.73)	-0.0000495*** (-4.04)	-0.0000445** (-2.93)
thresh	0.278*** (3.96)	-0.00629 (-0.14)	0.0314 (0.71)	-0.00629 (-0.23)
2013.ano		-0.00123 (-0.02)	-0.000775 (-0.01)	-0.00123 (-0.03)
2014.ano		0.101 (1.56)	0.104 (1.54)	0.101 (1.95)
2015.ano		0.133* (1.99)	0.162* (2.35)	0.133 (2.02)
2016.ano		-0.124 (-1.83)	-0.108 (-1.55)	-0.124 (-1.18)
2017.ano		0.172** (2.62)	0.174* (2.56)	0.172* (2.06)
2018.ano		0.155* (2.35)	0.153* (2.23)	0.155 (1.72)
2019.ano		0.294*** (4.37)	0.314*** (4.55)	0.294** (3.25)
2020.ano		0.307*** (4.58)	0.312*** (4.51)	0.307*** (3.80)
2021.ano		0.201** (3.06)	0.202** (2.97)	0.201* (2.11)
2022.ano		0.186** (2.70)	0.170* (2.39)	0.186 (1.95)
2023.ano		0.357*** (5.26)	0.380*** (5.47)	0.357*** (4.25)
2024.ano		0.335** (3.24)	0.446*** (4.61)	0.335** (3.37)
_cons	-7.668 (-1.94)	10.86*** (3.69)	9.205** (3.12)	10.86*** (6.39)

R ²	0.476	0.339	0.398	0.339
VIF Médio		274.73		
T. de Chow		81.26***		
T. de Hausman		29.02***		
T. de Breush-Pagan		1067.67***		
T. de Homocedasticidade (Wald)		1473.11***		
T. de Autocorrelação (Wooldridge)		10.849***		
T. Dep. Transversal (Pesaran)		-0.220 ^{NS}		

Nota: Estatísticas t em parênteses. * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$.

A tabela M2 apresenta os resultados da estrutura de dados em painel. O teste de Chow foi estatisticamente significativo ($F = 81,26$; $p < 0,001$), indicando que o modelo de efeitos fixos é preferível ao pooled OLS. O teste LM de Breusch–Pagan também apresentou significância estatística ($\chi^2 = 1.067,67$; $p < 0,001$), demonstrando que o modelo de efeitos aleatórios é superior ao pooled.

Na comparação entre efeitos fixos e efeitos aleatórios, o teste de Hausman foi significativo ($\chi^2 = 29,02$; $p < 0,001$), rejeitando a hipótese de consistência do estimador de efeitos aleatórios. Assim, o modelo de efeitos fixos mostrou-se mais adequado.

O teste de Wald modificado indicou heterocedasticidade entre os painéis ($\chi^2 = 1.473,11$; $p < 0,001$), enquanto o teste de Wooldridge apontou autocorrelação serial dos resíduos ($F = 10,849$; $p < 0,001$). Em razão dessas violações, adotou-se o modelo de efeitos fixos com erros-padrão robustos.

Por sua vez, o teste de Pesaran não foi estatisticamente significativo ($CD = -0,220$), não sendo identificada dependência transversal dos resíduos. O VIF médio foi de 274,73, evidenciando elevada multicolinearidade entre os termos lineares e quadráticos das variáveis climáticas, característica recorrente em especificações polinomiais. Portanto, os coeficientes lineares e quadráticos devem ser interpretados conjuntamente.

Tabela M3. Estimções para o Milho – Modelo 3 (Adaptação)

	(1) Pooled	(2) Efeitos Fixos	(3) Efeitos Aleatórios	(4) Efeitos Fixos Robustos
temp_med	-0.162*** (-9.47)	-0.0775** (-2.68)	-0.101*** (-3.83)	-0.0775** (-3.54)
adaptacao	0.00168*** (3.96)	0.00591*** (4.00)	0.00568*** (3.82)	0.00591** (2.81)
prec_med	0.00629*** (5.43)	0.00277** (3.16)	0.00293*** (3.38)	0.00277** (3.09)
2012.ano		0 (.)	0 (.)	0 (.)
2013.ano		-0.107 (-1.43)	-0.106 (-1.40)	-0.107 (-1.50)
2014.ano		-0.177 (-1.81)	-0.167 (-1.69)	-0.177 (-1.64)
2015.ano		-0.297* (-2.28)	-0.268* (-2.06)	-0.297 (-1.84)
2016.ano		-0.671*** (-4.12)	-0.642*** (-3.93)	-0.671** (-2.92)
2017.ano		-0.530** (-2.69)	-0.500* (-2.53)	-0.530* (-2.18)
2018.ano		-0.697** (-3.01)	-0.665** (-2.86)	-0.697* (-2.37)
2019.ano		-0.712** (-2.62)	-0.662* (-2.43)	-0.712 (-2.05)
2020.ano		-0.828** (-2.71)	-0.779* (-2.53)	-0.828* (-2.11)
2021.ano		-1.112** (-3.26)	-1.063** (-3.10)	-1.112* (-2.47)
2022.ano		-1.237** (-3.31)	-1.191** (-3.16)	-1.237* (-2.49)
2023.ano		-1.258** (-2.98)	-1.181** (-2.79)	-1.258* (-2.21)
2024.ano		-1.439** (-2.99)	-1.318** (-2.73)	-1.439* (-2.22)
_cons	11.19*** (24.48)	9.445*** (12.67)	10.01*** (14.40)	9.445*** (17.89)
R ²	0.291	0.342	0.282	0.342
VIF Médio		1.06		
T. de Chow		122.99***		
T. de Hausman		9.28*		
T. de Breush-Pagan		1638.90***		

T. de Homocedasticidade (Wald)	2310.8 ^{***}
T. de Autocorrelação (Wooldridge)	9.500 ^{***}
T. Dep. Transversal (Pesaran)	-0.407 ^{NS}

Nota: Estatísticas t em parênteses. * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$.

A Tabela M3 apresenta os resultados dos testes F de Chow apresentou estatística de 122,99 ($p < 0,001$), rejeitando a hipótese nula de inexistência de efeitos individuais e indicando que o modelo de efeitos fixos é mais apropriado do que o modelo pooled OLS.

O teste do multiplicador de Lagrange de Breusch–Pagan também foi estatisticamente significativo ($\chi^2 = 1.638,90$; $p < 0,001$), evidenciando que a estrutura em painel é superior ao modelo pooled, justificando a utilização de modelos que incorporam efeitos específicos das unidades analisadas. Para definir a especificação mais consistente entre os modelos de efeitos fixos e efeitos aleatórios, foi aplicado o teste de Hausman. A estatística obtida ($\chi^2 = 9,28$; $p < 0,05$) rejeitou a hipótese nula de ausência de correlação entre os efeitos individuais e as variáveis explicativas. Assim, o modelo de efeitos fixos mostrou-se o estimador mais adequado para a análise da produtividade do milho.

Na avaliação dos pressupostos dos resíduos, o teste de Wald modificado apresentou estatística de 2.310,80 ($p < 0,001$), indicando a presença de heterocedasticidade entre os painéis. De forma complementar, o teste de Wooldridge apresentou estatística F igual a 9,500 ($p < 0,001$), evidenciando autocorrelação serial dos resíduos. Diante dessas violações, a inferência estatística foi realizada com base no modelo de efeitos fixos com erros-padrão robustos, que fornece estimativas consistentes na presença de heterocedasticidade e autocorrelação. O teste de dependência transversal de Pesaran apresentou estatística de -0,407, sem significância estatística ($p > 0,10$), indicando ausência de dependência transversal entre os resíduos das unidades do painel.

Por fim, o diagnóstico de multicolinearidade apresentou VIF médio de 1,06, valor muito inferior ao limite convencional de 10, indicando ausência de multicolinearidade relevante entre as variáveis explicativas e evidenciando que os coeficientes estimados não foram afetados por correlação linear excessiva entre os regressores.

Tabela S1. Estimções para a Soja – Modelo 1 (*Baseline*)

	(1) Pooled	(2) Efeitos Fixos	(3) Efeitos Aleatórios	(4) Efeitos Fixos Robustos
temp_med	-0.00583 (-1.36)	-0.0386* (-2.06)	-0.0121 (-1.88)	-0.0386 (-2.01)
prec_med	-0.0000864 (-0.25)	0.00223*** (3.60)	0.000883* (2.07)	0.00223** (3.72)
2013.ano		-0.0388 (-0.77)	-0.0144 (-0.28)	-0.0388 (-0.71)
2014.ano		-0.0155 (-0.31)	-0.0213 (-0.41)	-0.0155 (-0.35)
2015.ano		0.0387 (0.77)	0.0216 (0.41)	0.0387 (0.77)
2016.ano		-0.0654 (-1.32)	-0.0650 (-1.26)	-0.0654 (-0.78)
2017.ano		0.102* (2.06)	0.107* (2.07)	0.102 (1.89)
2018.ano		0.104* (2.12)	0.123* (2.41)	0.104 (1.94)
2019.ano		0.133** (2.72)	0.119* (2.34)	0.133** (2.97)
2020.ano		0.148** (3.07)	0.146** (2.92)	0.148** (3.56)
2021.ano		0.147** (3.08)	0.159** (3.23)	0.147** (2.85)
2022.ano		0.0427 (0.87)	0.0636 (1.28)	0.0427 (1.11)
2023.ano		0.250*** (5.22)	0.226*** (4.61)	0.250*** (6.96)
2024.ano		0.226*** (3.80)	0.158** (3.14)	0.226*** (4.16)
_cons	8.174*** (69.35)	8.669*** (18.13)	8.138*** (47.06)	8.669*** (17.87)
R ²	0.00700	0.291	0.174	0.291
VIF Médio		1.01		
T. de Chow		4.57***		
T. de Hausman		29.52***		
T. de Breush-Pagan		46.74***		
T. de Homocedasticidade (Wald)		5.6e+28***		
T. de Autocorrelação (Wooldridge)		3.454*		
T. Dep. Transversal (Pesaran)		-1.402 ^{NS}		

Nota: Estatísticas t em parênteses. * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$.

A Tabela S1 apresenta os resultado dos testes de Chow foi significativo ($F = 4,57$; $p < 0,001$), indicando que o modelo de efeitos fixos é preferível ao modelo pooled OLS. O teste de Breusch–Pagan também foi significativo ($\chi^2 = 46,74$; $p < 0,001$), confirmando a adequação da estrutura de dados em painel.

O teste de Hausman ($\chi^2 = 29,52$; $p < 0,001$) indicou que o modelo de efeitos fixos é mais consistente do que o modelo de efeitos aleatórios. Assim, as interpretações foram baseadas na especificação de efeitos fixos.

Os testes de Wald ($\chi^2 = 5,6 \times 10^{28}$; $p < 0,001$) e de Wooldridge ($F = 3,454$; $p < 0,05$) evidenciaram a presença de heterocedasticidade e autocorrelação serial dos resíduos. Dessa forma, adotou-se o modelo de efeitos fixos com erros-padrão robustos.

O teste de Pesaran não foi significativo ($CD = -1,402$; $p > 0,10$), indicando ausência de dependência transversal entre os painéis. Por fim, o VIF médio de 1,01 mostrou que não há problemas de multicolinearidade entre as variáveis explicativas.

Tabela S2. Estimções para a Soja – Modelo 2 (Não linearidade)

	(1) Pooled	(2) Efeitos Fixos	(3) Efeitos Aleatórios	(4) Efeitos Fixos Robustos
temp_med	0.335** (3.06)	0.107 (0.51)	0.402** (3.12)	0.107 (0.48)
c.temp_med#c.t emp_med	-0.00728** (-3.00)	-0.00347 (-0.72)	-0.00906** (-3.15)	-0.00347 (-0.65)
prec_med	0.00241 (1.34)	0.00274 (1.19)	0.00236 (1.28)	0.00274 (1.61)
c.prec_med#c.p rec_med	-0.00000894 (-1.15)	-0.00000198 (-0.22)	-0.00000540 (-0.69)	-0.00000198 (-0.32)
thresh	0.0220 (0.97)	0.0332 (0.81)	0.0483 (1.82)	0.0332 (0.91)
2013.ano		-0.0322 (-0.62)	-0.00130 (-0.02)	-0.0322 (-0.60)
2014.ano		-0.0120 (-0.24)	-0.0217 (-0.42)	-0.0120 (-0.27)
2015.ano		0.0417 (0.82)	0.0285 (0.54)	0.0417 (0.80)
2016.ano		-0.0625 (-1.23)	-0.0549 (-1.06)	-0.0625 (-0.74)
2017.ano		0.0994* (1.99)	0.0998 (1.93)	0.0994 (1.79)
2018.ano		0.106* (2.15)	0.124* (2.43)	0.106 (1.93)
2019.ano		0.136** (2.74)	0.120* (2.35)	0.136** (2.98)
2020.ano		0.148** (3.04)	0.148** (2.92)	0.148** (3.49)
2021.ano		0.150** (3.11)	0.164*** (3.31)	0.150** (2.91)
2022.ano		0.0428 (0.87)	0.0620 (1.25)	0.0428 (1.15)
2023.ano		0.254*** (5.20)	0.231*** (4.71)	0.254*** (6.62)
2024.ano		0.257*** (3.45)	0.200*** (3.72)	0.257** (3.11)
_cons	4.084** (3.30)	7.140** (3.17)	3.348* (2.31)	7.140** (3.28)

R ²	0.0607	0.293	0.253	0.293
VIF Médio		305.42		
T. de Chow		3.40***		
T. de Hausman		31.41***		
T. de Breush-Pagan		18.63***		
T. de Homocedasticidade (Wald)		1229.48***		
T. de Autocorrelação (Wooldridge)		4.967**		
T. Dep. Transversal (Pesaran)		-1.382 ^{NS}		

Nota: Estatísticas t em parênteses. * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$.

A tabela S2 apresenta os resultados dos testes: O teste de Chow foi significativo ($F = 3,40$; $p < 0,001$), indicando que o modelo de efeitos fixos é preferível ao modelo pooled OLS. O teste de Breusch–Pagan também foi significativo ($\chi^2 = 18,63$; $p < 0,001$), confirmando a adequação da estrutura de dados em painel.

O teste de Hausman ($\chi^2 = 31,41$; $p < 0,001$) indicou que o modelo de efeitos fixos é mais consistente que o modelo de efeitos aleatórios. Assim, as interpretações foram baseadas na especificação de efeitos fixos.

Os testes de Wald ($\chi^2 = 1.229,48$; $p < 0,001$) e de Wooldridge ($F = 4,967$; $p < 0,01$) evidenciaram a presença de heterocedasticidade e autocorrelação serial dos resíduos. Dessa forma, adotou-se o modelo de efeitos fixos com erros-padrão robustos.

O teste de Pesaran não foi significativo ($CD = -1,382$; $p > 0,10$), indicando ausência de dependência transversal entre os painéis. Por fim, o VIF médio de 305,42 evidenciou elevada multicolinearidade entre os termos lineares e quadráticos das variáveis climáticas, comportamento esperado em modelos que incluem termos polinomiais. Portanto, os coeficientes linear e quadrático devem ser interpretados conjuntamente.

Tabela S3. Estimções para a Soja – Modelo 3 (Adaptação)

	(1) Pooled	(2) Efeitos Fixos	(3) Efeitos Aleatórios	(4) Efeitos Fixos Robustos
temp_med	-0.0129** (-3.07)	-0.0405* (-2.13)	-0.0164 (-1.87)	-0.0405* (-2.08)
adaptacao	0.000667*** (5.93)	0.000568 (0.57)	0.000715 (0.70)	0.000568 (0.47)
prec_med	-0.00000115 (-0.00)	0.00220*** (3.54)	0.000908* (2.10)	0.00220*** (3.91)
2013.ano		-0.0527 (-0.94)	-0.0331 (-0.57)	-0.0527 (-0.97)
2014.ano		-0.0437 (-0.62)	-0.0569 (-0.79)	-0.0437 (-0.74)
2015.ano		-0.00409 (-0.05)	-0.0311 (-0.34)	-0.00409 (-0.05)
2016.ano		-0.122 (-1.10)	-0.136 (-1.20)	-0.122 (-0.88)
2017.ano		0.0311 (0.23)	0.0175 (0.13)	0.0311 (0.22)
2018.ano		0.0199 (0.13)	0.0157 (0.10)	0.0199 (0.13)
2019.ano		0.0334 (0.18)	-0.00622 (-0.03)	0.0334 (0.18)
2020.ano		0.0338 (0.17)	0.00307 (0.01)	0.0338 (0.15)
2021.ano		0.0199 (0.09)	-0.00150 (-0.01)	0.0199 (0.08)
2022.ano		-0.0979 (-0.39)	-0.115 (-0.45)	-0.0979 (-0.33)
2023.ano		0.0916 (0.33)	0.0274 (0.10)	0.0916 (0.28)
2024.ano		0.0455 (0.14)	-0.0643 (-0.20)	0.0455 (0.13)
_cons	8.236*** (73.92)	8.719*** (17.92)	8.242*** (35.86)	8.719*** (18.07)
R ²	0.124	0.292	0.173	0.292
VIF Médio		1.07		
T. de Chow		4.55***		
T. de Hausman		27.26***		
T. de Breush-Pagan		47.09***		
T. de Homocedasticidade (Wald)		1.2e+29***		

T. de Autocorrelação (Wooldridge)	2.618 ^{NS}
T. Dep. Transversal (Pesaran)	-1.441 ^{NS}

Nota: Estatísticas t em parênteses. * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$.

A tabela S3 apresenta os resultados dos testes: O teste de Chow foi significativo ($F = 4,55$; $p < 0,001$), indicando que o modelo de efeitos fixos é preferível ao modelo pooled OLS. O teste de Breusch–Pagan também foi significativo ($\chi^2 = 47,09$; $p < 0,001$), confirmando a adequação da estrutura de dados em painel.

O teste de Hausman ($\chi^2 = 27,26$; $p < 0,001$) indicou que o modelo de efeitos fixos é mais consistente do que o modelo de efeitos aleatórios. Assim, as interpretações foram baseadas na especificação de efeitos fixos.

O teste de Wald ($\chi^2 = 1,2 \times 10^{29}$; $p < 0,001$) evidenciou a presença de heterocedasticidade entre os painéis. Por outro lado, os testes de Wooldridge ($F = 2,618$; $p > 0,10$) e de Pesaran ($CD = -1,441$; $p > 0,10$) não foram significativos, indicando ausência de autocorrelação serial e de dependência transversal dos resíduos. Dessa forma, adotou-se o modelo de efeitos fixos com erros-padrão robustos. Por fim, o VIF médio de 1,07 indicou ausência de multicolinearidade relevante entre as variáveis explicativas.